

UNIVERSITÉ DU QUÉBEC À TROIS-RIVIÈRES

**OPTIMISATION DE COÛT DE PRODUCTION DE L'ÉLECTRICITÉ DANS UN
MICRO RÉSEAU ÉLECTRIQUE**

**THÈSE PRÉSENTÉE
COMME EXIGENCE PARTIELLE DU
DOCTORAT EN GÉNIE ÉLECTRIQUE**

**PAR
SENGTHAVY PHOMMIXAY**

MARS 2021

Université du Québec à Trois-Rivières

Service de la bibliothèque

Avertissement

L'auteur de ce mémoire ou de cette thèse a autorisé l'Université du Québec à Trois-Rivières à diffuser, à des fins non lucratives, une copie de son mémoire ou de sa thèse.

Cette diffusion n'entraîne pas une renonciation de la part de l'auteur à ses droits de propriété intellectuelle, incluant le droit d'auteur, sur ce mémoire ou cette thèse. Notamment, la reproduction ou la publication de la totalité ou d'une partie importante de ce mémoire ou de cette thèse requiert son autorisation.

UNIVERSITÉ DU QUÉBEC À TROIS-RIVIÈRES

DOCTORAT EN GÉNIE ÉLECTRIQUE (Ph. D.)

Direction de recherche :

Mamadou Lamine Doumbia

Directeur de recherche

Jury d'évaluation :

Mamadou Lamine Doumbia

Directeur de recherche

Alben Cardenas

Président du jury

Mohamed Benhaddadi

Évaluateur externe

Karim Belmokhtar

Évaluateur externe

Thèse soutenue le 07 janvier 2021

Résumé

Les réseaux électriques actuels sont en train de se transformer en micro réseaux (MG) intelligents et réseaux intelligents (smart grid). Les tendances récentes des MG incluent l'intégration des sources d'énergie renouvelable (RES) afin de produire de l'électricité avec une faible émission et à moindre coût. Cependant, à cause de la variabilité et de l'imprévisibilité de ces sources, leur utilisation efficace exige la combinaison avec les sources d'énergie conventionnelle et le système de stockage d'énergie. Cependant, cela entraîne de nouveaux défis pour la conception d'un système de gestion intelligente. Les méthodes traditionnelles de gestion et planification reposent sur la prévision parfaite de la production et la demande. Elles ne peuvent plus s'appliquer au MG avec des RES intermittentes, car ces modèles déterministes manquent de robustesse contre les incertitudes.

Cette thèse développe une approche d'optimisation à deux niveaux pour la planification et le fonctionnement en temps réel du MG. La formulation à l'étape de planification caractérise l'incertitude de la ressource renouvelable sous forme de contrainte probabiliste et sous forme de problème robuste-stochastique basé sur des scénarios. Afin de résoudre efficacement le problème de contrainte probabiliste, nous proposons une approche d'optimisation robuste de distribution à contraintes aléatoires (Distributionnally robust chance-constrained optimization) en se basant sur l'approche d'optimisation robuste de distribution (Distributionnally robust optimization). La formulation équivalente pourrait

être traitée par la méthode d'optimisation simple telle que l'optimisation par essaim particulière (PSO). Ensuite, nous développons une approche robuste via la coévolution de l'algorithme PSO afin de résoudre le problème robuste-stochastique. Les résultats optimaux obtenus dans l'étape de planification ont été reoptimisés à court terme pour caractériser le fonctionnement en temps réel du MG.

Nous avons également introduit l'incertitude de la maintenance préventive. Ce paramètre a été représenté sous forme de contrainte probabiliste. Dans le même contexte de l'optimisation à deux niveaux, le modèle proposé a été modifié et étendu au modèle distribué afin de caractériser l'interaction dans un système composé de plusieurs MG. À cette fin, l'approche de calcul séquentiel a été proposée afin de réduire la complexité du calcul tout en maintenant la qualité du résultat.

Remerciements

Je souhaite remercier ma famille pour le soutien, la compréhension et l'accompagnement continu tout au long de mes études.

Je tiens également à remercier mes superviseurs, le professeur Mamadou Lamine Doumbia et le professeur David Lupien St-Pierre pour leur soutien et leurs conseils tout au long du travail de thèse.

Je suis très reconnaissant au professeur Mamadou Lamine Doumbia pour les diverses opportunités qu'il a mises à disposition pour développer mes compétences et acquérir une expérience dans le monde de la recherche.

Je tiens à remercier les membres de l'équipe du Programme Canadien de Bourses de la Francophonie pour l'accueil chaleureux et les discussions perspicaces pendant mon séjour au Canada. Le travail de thèse n'aurait pas été possible sans leur soutien financier.

Je tiens également à remercier les membres du Bureau des Relations Internationales pour leurs accueils et conseils pendant mon séjour à l'UQTR.

Enfin, je tiens à remercier mes collègues et amis du Laboratoire Conversion d'énergie électrique et qualité de l'onde ainsi que du département génie électrique et génie informatique pour leur sympathie. J'ai apprécié les discussions académiques et non académiques que nous avons eues et l'environnement de travail propice que nous avons partagé.

Table des matières

Résumé.....	iii
Remerciements.....	v
Liste des tableaux.....	x
Liste des figures	xi
Liste des symboles	xiii
Liste des abréviations.....	xvi
Chapitre 1 - Introduction.....	1
Chapitre 2 - Revue de littérature des méthodes d'optimisation et de gestion.....	8
2.1 Méthodes d'optimisation	8
2.2 Méthodes de gestion hors ligne et en temps réel.....	21
2.3 Méthodes de gestion coopérative et distribuée.....	29
2.4 Analyses de la revue de littérature sur les méthodes de gestion	36
2.5 Conclusion.....	37
Chapitre 3 - Modèle et outil de simulation du MG	39
3.1 Variables d'optimisation	39

3.2	Modèles des composants	41
3.3	Étapes nécessaires pour le dimensionnement optimal d'un MG.....	44
3.4	Fonction de coût	45
3.5	Contraintes.....	47
3.6	Commande prédictive.....	49
3.7	Modèle à risque proportionnel	52
3.8	Valeur de Shapley	53
3.9	Conclusion.....	54
Chapitre 4 - Modèle d'optimisation hiérarchisé pour la planification et		
	l'opération en temps réel du MG	55
4.1	Formulation du modèle d'optimisation hiérarchisé.....	55
4.2	Simulation	64
4.3	Conclusion.....	78
Chapitre 5 - Modèle d'optimisation hiérarchisé pour la planification et		
	l'opération en temps réel du MG intégrant l'approche robuste-stochastique.....	80
5.1	Modélisation de l'incertitude basée sur les scénarios	80
5.2	Formulation d'optimisation robuste sous l'impact de l'incertitude du profil de vent	83
5.3	Modèle d'optimisation hiérarchisé.....	84
5.4	Approche d'optimisation robuste	87

5.5 Résultats d'optimisation	90
5.6 Conclusion.....	97
Chapitre 6 - Modèle d'optimisation distribué et hiérarchisé pour la planification et l'opération en temps réel des MG considérant la maintenance préventive	99
6.1 Modèle de gestion distribué	99
6.2 Modèle de gestion hiérarchisé	102
6.3 Simulation	110
6.4 Conclusion.....	119
Chapitre 7 - Conclusion	120
7.1 Résumé de la recherche	120
7.2 Contributions scientifiques.....	122
7.3 Recommandation de travaux futurs.....	123
Publications.....	125
Références	127
Annexes.....	135
Annexe A – Formulation du problème sous variables aléatoires dépendantes et dynamiques (chapitre 4)	135
Annexe B – Paramètres d'optimisation hors ligne (chapitre 4).....	137
Annexe C – Paramètres du moment d'ordre 2 de l'erreur de prévision de la puissance du WT (chapitre 4).....	138

Annexe D – Paramètres d’optimisation en temps réel (chapitre 4)	138
Annexe E – Paramètres de simulation des différentes sources (chapitre 4)	138
Annexe F – Paramètres d’optimisation (chapitre 6)	139
Annexe G – Paramètres de simulation des différentes sources (chapitre 6).....	139
Annexe H – Paramètres du moment d’ordre 2 de l’erreur de la maintenance planifiée (chapitre 6)	140

Liste des tableaux

Tableau 2-1	Classification des méthodes d'optimisation	9
Tableau 4-1	Coût d'opération obtenu par le PSO	73
Tableau 4-2	Coût d'opération sous différents niveaux de confiance (obtenu par le PSO)	73
Tableau 4-3	Coût d'opération obtenu par l'approche déterministe	76
Tableau 4-4	Coût d'opération obtenu par l'approche DRCCP	77
Tableau 5-1	Coût d'opération obtenu par l'approche robuste-stochastique (20 scénarios)	95
Tableau 5-2	Coût d'opération obtenu par l'optimisation à deux niveaux	96
Tableau 6-1	Coût total d'opération des MG	113
Tableau 6-2	Coût total d'opération sous deux modes d'opération	117
Tableau 6-3	Coût d'opération sous différentes coalitions de MG	117
Tableau 6-4	Permutations des MG	118

Liste des figures

Figure 2.1	Procédure de l'algorithme PSO	13
Figure 2.2	Structure de l'algorithme MAPSO	15
Figure 2.3	Communication interactive d'un agent	17
Figure 2.4	Structure du modèle de gestion hiérarchisé basée sur la MPC	24
Figure 2.5	Structure du modèle centralisé et décentralisé	30
Figure 3.1	Comparaison des zones de fonctionnement du DG	41
Figure 3.2	Principe de la MPC	50
Figure 3.3	Principe de changement de l'horizon de prévision	52
Figure 4.1	Modèle d'optimisation hiérarchisé du MG	63
Figure 4.2	Profil de charge	65
Figure 4.3	Puissance du WT	65
Figure 4.4	Prix d'échange d'électricité du réseau	66
Figure 4.5	Résultat obtenu par l'optimisation hors ligne	69
Figure 4.6	Résultat obtenu par l'optimisation en temps réel	72
Figure 4.7	Résultat obtenu par l'optimisation à deux niveaux (PSO)	76
Figure 4.8	Impact du dimensionnement de la BESS sur le coût total d'opération	78
Figure 5.1	Procédure de la méthode FS	82
Figure 5.2	Scénarios de la vitesse du vent (100 scénarios)	82
Figure 5.3	Scénarios (réduit) de la vitesse du vent (20 scénarios)	83
Figure 5.4	Procédure de calcul du modèle d'optimisation hiérarchisé	85

Figure 5.5	Diagramme de l'algorithme PSO-PSO.....	89
Figure 5.6	Profil de charge.....	90
Figure 5.7	Puissance du WT (associée au cinquième scénario de la vitesse du vent).....	91
Figure 5.8	Résultat obtenu au niveau supérieur par le cinquième scénario de la vitesse du vent (approche robuste-stochastique)	93
Figure 5.9	Résultat obtenu par l'optimisation à deux niveaux	95
Figure 5.10	Convergence de l'algorithme PSO-PSO.....	97
Figure 6.1	Structure des MG avec l'échange d'énergie entre eux (Mode séquentielle).....	102
Figure 6.2	Procédure de calcul du modèle d'optimisation distribué et hiérarchisé des MG.....	109
Figure 6.3	Prix d'échange d'électricité du réseau	110
Figure 6.4	Profil de charge.....	111
Figure 6.5	Puissance du WT	111
Figure 6.6	Résultats obtenus par le modèle distribué-hiérarchisé du premier MG.....	114
Figure 6.7	Résultats obtenus par le modèle distribué-hiérarchisé du deuxième MG.....	115
Figure 6.8	Résultats obtenus par le modèle distribué-hiérarchisé du troisième MG.....	116

Liste des symboles

P_{dg}	Puissance de sortie du générateur diesel en kW
P_g	Puissance du réseau en kW
P_{gbuy}	Puissance d'achat d'électricité en kW
P_{gsell}	Puissance de vente d'électricité en kW
P_{bess}	Puissance de la batterie en kW
P_{ch}	Puissance de charge de la batterie en kW
P_{disch}	Puissance de décharge de la batterie en kW
P_{wt}	Puissance de sortie de l'éolienne en kW
P_{dg_min}	Puissance minimale du diesel en kW
P_{dg_max}	Puissance maximale du diesel en kW
P_{gbuy_max}	Puissance maximale d'achat d'électricité en kW
P_{gsell_max}	Puissance maximale de vente d'électricité en kW
SOC_{min}	Valeur minimale de l'état de charge en %
SOC_{max}	Valeur maximale de l'état de charge en %
η_{ch}	Rendement de charge de la batterie en %
η_{disch}	Rendement de décharge de la batterie en %
P_{load}	Puissance de charge (demande) en kW
NC_{bess}	Capacité nominale de la batterie en kWh
C_{op}	Coût total d'opération en \$

C_{wt}	Coût lié au fonctionnement de l'éolienne en \$
C_{bess}	Coût d'utilisation de la batterie en \$
C_{dg}	Coût d'opération du générateur diesel en \$
C_g	Coût d'énergie du réseau en \$
$C_{op_mg,i}$	Coût total d'opération du MG No. i en \$
$C_{mg,i \rightarrow j}$	Coût d'échange d'énergie du MG No. i vers le MG No. j en \$
$P_{mg,i \rightarrow j}$	Flux de puissance du MG No. i vers le MG No. j en \$
FC	Coût de carburant en \$
MC	Coût de maintenance en \$
PCC	Coût par cycle de la batterie en \$
OPC	Coût d'opération de la batterie en \$
t	Indice de temps en h
T	Horizon de temps de simulation en h
ΔT	Pas de temps en min ou h
ζ_{wt}	Variable aléatoire représentant l'erreur de prévision de la puissance du WT
ζ_{load}	Variable aléatoire représentant l'erreur de prévision de la charge
ζ_{out}	Variable aléatoire représentant l'erreur du temps estimé pour la maintenance
ϵ	Niveau de confiance en %
dg	Facteur de participation
U	État de marche/arrêt de la source (0/1)
u	État de la maintenance (0/1)
t_{out}	Temps estimé pour la maintenance en h
T_{max}	Temps maximal autorisé pour la maintenance en h
μ_{wt}, μ_{load}	Erreur moyenne de la puissance du WT et de la charge en kW

$\Sigma_{wt}, \Sigma_{load}$ Matrice de covariance de l'erreur de la puissance du WT et de la charge en kW

$\sigma_{wt}, \sigma_{load}$ Écart-type de l'erreur de la puissance du WT et de la charge en kW

μ_{out} Erreur moyenne du temps estimé de la maintenance en h

Σ_{out} Matrice de covariance de l'erreur du temps estimé de la maintenance en h

σ_{out} Écart-type de l'erreur du temps estimé de la maintenance en h

D_{wt}, D_{load} Ensemble d'ambigüités associé au WT et à la charge

D_{out} Ensemble d'ambigüités associé à la maintenance du DG

Symboles utilisés pour l'algorithme PSO

P_{best} Meilleure position locale

G_{best} Meilleure position globale

c_1, c_2 Coefficients d'accélération

r_1, r_2 Nombres aléatoires entre 0 et 1

X Particule de l'essaim

V Vitesse de la particule

w Inertie

k_{max} Nombre maximal d'itérations

k Indice d'itération

N Nombre de particules

D Dimension

Liste des abréviations

ABC	Algorithme de colonie d'abeilles artificielles (artificial bee colony algorithm)
ACO	Algorithme de colonies de fourmis (ant colony optimization)
ANN	Réseau de neurones artificiels (artificial neural network)
ARMA	Modèle autorégressif et moyenne mobile (autoregressive moving average model)
AH-MPC	Commande prédictive à l'horizon variable (variable horizon model predictive control)
BESS	Système de stockage d'énergie par batterie (battery energy storage system)
DE	Algorithme à évolution différentielle (differential evolution)
DMPC	Commande prédictive distribuée (distributed model predictive control)
DRO	Optimisation robuste de distribution (distributionally robust optimisation)
DRCCP	Optimisation robuste de distribution à contraintes aléatoires (distributionally robust chance-constrained programming)
DP	Programmation dynamique (dynamic programming)
DG	Générateur diesel (diesel generator)
ESS	Système de stockage d'énergie (energy storage system)
FL	Logique floue (fuzzy logic)
FS	Sélection directe (forward selection)
GA	Algorithme génétique (genetic algorithm)

HBPSO	Hybride binaire optimisation par essaim particulaire (hybrid binary particle swarm optimization)
MG	Micro-réseau (microgrid)
MAPSO	Multi-agent PSO
MC	Simulation de Monte-Carlo (Monte Carlo simulation)
MPC	Commande prédictive (model predictive control)
PSO	Optimisation par essaim particulaire (particle swarm optimization)
PHM	Modèle à risque proportionnel (proportional hazards model)
RES	Sources d'énergie renouvelable (renewable energy sources)
SA	Recuit simulé (simulated annealing)
SOC	État de charge (state of charge)
UC	Engagement de la source de production (unit commitment)
WT	Turbine éolienne (wind turbine)

Chapitre 1 - Introduction

Les micro réseaux (MG) ont fourni une motivation substantielle pour le développement d'une approche plus intelligente, plus résiliente et rentable pour la production d'énergie électrique. Les MG sont principalement construits à partir des sources d'énergie renouvelable (RES) en se concentrant sur l'indépendance des approvisionnements énergétiques locaux.

Le MG encourage l'intégration des RES pour réaliser l'objectif de développement durable. Le MG améliore également la fiabilité, l'efficacité, la résilience et la sécurité des systèmes d'alimentation électrique face aux événements inattendus et critiques. Le MG peut se connecter au réseau (en mode connecté au réseau) ou fonctionner indépendamment du réseau (en mode autonome).

La principale préoccupation économique pour les MG consiste à l'utilisation efficace des RES et des sources d'énergie conventionnelle. Le coût de production d'énergie peut être minimisé en agissant sur le dimensionnement et/ou ajustant les opérations du MG. Dans [1], les auteurs montrent l'influence du dimensionnement sur le coût de production d'énergie. Les sources et les dispositifs de stockage sous-dimensionnés ne peuvent pas fournir d'avantages économiques, de flexibilité ou de fiabilité dans les MG. Cependant, les sources et les dispositifs de stockage trop grands entraînent des coûts d'investissement et des coûts de maintenance plus élevés [2].

Les travaux de recherche sur les MG peuvent être divisés en étude des décisions d'investissement et d'exploitation. Premièrement, l'étude de l'investissement des MG porte sur le dimensionnement optimal des composants. Deuxièmement, l'étude sur l'opération traite de la stratégie optimale une fois que les composants sont déjà en place. Ces deux études ont l'objectif principal de maximiser les avantages économiques des MG.

- **Avantage du MG**

Les MG sont une solution prometteuse pour maximiser les bénéfices des consommateurs et des producteurs. Les MG bénéficient en effet d'atouts significatifs sur le réseau traditionnel. La proximité de la production permet d'optimiser la distribution de l'énergie et de réduire les pertes d'énergie liées au transport de l'électricité. Il leur est possible d'obtenir une meilleure efficacité grâce à une production directement ajustée au besoin. L'efficacité peut être également améliorée grâce à la possibilité de mixer l'électricité et la chaleur évitant la perte d'une grande quantité d'énergie sous forme de chaleur dans les réseaux traditionnels.

- **Vers un MG intelligent (Smart MG)**

L'injection massive d'une production décentralisée sur le réseau de distribution peut avoir un impact sur son fonctionnement, qui peut s'étendre jusqu'au réseau de transport: impact sur les grandeurs électriques (puissance, tension, etc.), sur l'exploitation du réseau (stabilité, continuité et qualité de service, etc.). Le réseau de distribution actuel doit évoluer vers le réseau plus flexible et intelligent, favorisant l'intégration des RES. Ainsi, le problème majeur lié à l'exploitation du réseau électrique est de maintenir en permanence

l'équilibre entre l'offre et la demande. Nous sommes donc confrontés à un besoin du système de gestion intelligente de la production d'énergie.

Les MG fournissent les modèles de production d'énergie de petite à grande échelle et de déploiement du smart MG. Les opérateurs ont, grâce à ces MG, l'opportunité de se rapprocher des grandes compagnies afin de coopérer de façon plus efficace pour gérer une distribution d'énergie. De plus, la simplicité de ces MG pour intégrer les RES et les systèmes de stockage d'énergie (ESS) les rend très attractifs pour les opérateurs. Les infrastructures nécessaires aux réseaux électriques intelligents sont très difficiles à mettre en place et peuvent prendre plusieurs années. Les MG deviennent donc une alternative plus simple à mettre en œuvre et pourraient jouer un rôle important dans le développement des réseaux électriques intelligents.

❖ **Problématique**

La production d'énergie électrique par les RES dans les MG semble constituer une des réponses pertinentes au défi énergétique actuel. Cependant, l'association des ESS à la production et avec d'autres sources d'énergie conventionnelles est indispensable afin de garantir la fiabilité. La recherche du fonctionnement optimal de ces MG est devenue un problème complexe lorsque le recours aux différentes sources est envisagé. Chaque source devrait fournir la puissance avec le moindre coût possible selon les paramètres d'entrée (le profil de charge et de météo). Ces paramètres représentent des incertitudes dans la planification et le fonctionnement réel du MG.

Cette thèse développe une approche de gestion par optimisation à deux niveaux pour la planification et le fonctionnement en temps réel du MG en reconnaissant les incertitudes de la production et la demande.

Dans le même contexte de formulation à deux niveaux, la thèse tente également d'introduire l'incertitude de la production sous forme de problème stochastique basée sur les scénarios. Ici, le problème d'optimisation pourrait être représenté comme un problème d'optimisation robuste-stochastique dont le devoir est d'assurer une solution fiable et robuste à ce problème.

De manière encore plus réelle, l'opérateur du MG devrait être capable de prévenir l'interruption due à la maintenance préventive des sources de production. Par conséquent, cette thèse vise à traiter la planification de la maintenance préventive ainsi que l'incertitude liée au temps prévu pour la maintenance.

Le travail de thèse cherche en outre une approche et une méthodologie pour formuler la coopération de plusieurs MG et quantifier la répartition équitable des coûts d'opération. Notre modèle adopte l'approche séquentielle et unidirectionnelle pour simplifier l'échange d'information entre les MG. Encore une fois, cette approche définit les avantages de la coopération entre les MG tout en réduisant le coût total d'opération, et détermine les bénéfices vis-à-vis du fonctionnement indépendant des MG.

❖ Objectifs

Ce travail de thèse établit plusieurs défis à relever pour la planification et le fonctionnement réel du MG :

- Formuler le problème d'optimisation de manière à pouvoir coordonner efficacement la planification et le fonctionnement en temps réel.
- Inclure les paramètres d'incertitudes liés à la production et la demande ainsi que la disponibilité des sources de production, dans la planification afin de rassurer la robustesse au sein du MG.
- Concevoir un outil et une méthode efficace pour résoudre les problèmes d'optimisation probabiliste et robuste-stochastique.
- Modéliser une approche de planification et fonctionnement réel d'un système composé de plusieurs MG qui caractérise les interactions entre eux.

❖ Contributions

Les principales contributions de cette thèse peuvent être répertoriées comme suit:

- La thèse propose un modèle d'optimisation hiérarchisé à deux niveaux pour la planification et le fonctionnement en temps réel du MG, impliquant une interaction hiérarchique unidirectionnelle entre le niveau inférieur et supérieur, qui prend en compte des incertitudes liées à la production et la demande. Le problème de la planification est formulé sous des contraintes probabilistes, et ensuite transformé en un problème déterministe équivalent qui peut être résolu efficacement par les méthodes d'optimisation simples. La transformation proposée est basée sur l'optimisation robuste de distribution (Distributionally Robust Optimisation : DRO), qui est une technique émergente pour gérer le problème d'optimisation robuste. Il fournit une approche intermédiaire entre l'approche robuste et stochastique et améliore la conservabilité de ces deux approches. L'approche

d'optimisation en temps réel a également été développée pour réduire l'écart entre la planification et le fonctionnement en temps réel.

- Un modèle d'optimisation hiérarchisé à deux niveaux pour la planification et le fonctionnement en temps réel du MG basé sur le caractère stochastique de l'énergie éolienne a été conçu. La méthode d'optimisation par essais particuliers (PSO) à double couche a été proposée pour fournir la solution robuste face à ce problème d'optimisation stochastique. Cette méthode est simple et efficace pour la résolution des problèmes d'optimisation robuste-stochastique. De plus, l'approche d'optimisation en temps réel est intégrée pour ajuster les résultats obtenus par l'optimisation robuste-stochastique.
- Un modèle d'optimisation distribué et hiérarchisé à deux niveaux pour la planification et le fonctionnement en temps réel des MG couplés, impliquant une interaction séquentielle et unidirectionnelle entre chaque MG, a été développé. La stratégie de calcul séquentiel permet aux MG de se coordonner tout en minimisant l'effort de calcul. Notre modèle tient compte également de la planification de la maintenance des composants dans le plan de l'opération, le problème inclut donc les incertitudes liées à la maintenance. Ainsi, le problème de répartition équitable des coûts d'opération entre les MG est abordé.

❖ Organisation de la thèse

Cette thèse se compose de sept chapitres. **Au chapitre 2**, la revue de littérature sur les méthodes d'optimisation et de gestion des MG a été présentée. Dans la première partie, les méthodes d'optimisation utilisées pour l'application dans les MG sont introduites, en soulignant l'algorithme PSO. Dans la deuxième partie, les travaux sur les méthodes de

gestion hiérarchisée et distribuée ont été introduits. **Le chapitre 3** décrit les variables d'optimisation proposées telles que les variables continues, binaires et mixtes discrètes/continues. Ce chapitre propose également une description des modèles mathématiques les plus courants pour la modélisation du MG. L'accent est également mis sur les outils mathématiques proposés dans la littérature pour effectuer des simulations liées au problème de la planification du MG. **Le chapitre 4** développe les stratégies d'optimisation hors ligne et en temps réel tout en évaluant l'impact de la précision des prévisions sur le fonctionnement du MG. La partie restante du chapitre présente l'approche à deux niveaux composée des stratégies de gestion hors ligne et temps réel. **Le chapitre 5** développe l'approche d'optimisation hiérarchisée à deux niveaux. Afin de compléter le chapitre 4, ce chapitre propose une nouvelle approche robuste pour résoudre le problème d'optimisation stochastique. Nous fournissons les détails de la formulation ainsi que la solution du problème dont l'objectif est de développer l'algorithme PSO à double couche pour résoudre le problème d'optimisation robuste-stochastique. **Le chapitre 6** propose l'approche d'optimisation distribuée et hiérarchisée pour appliquer à un système composé de nombreux MG en tenant compte de la maintenance préventive. En plus, cette étude évalue comment chaque MG pourrait obtenir le coût de façon équitable sous le fonctionnement interactif avec d'autres MG. Enfin, **le chapitre 7** conclut les différentes réalisations de la thèse et propose quelques points qui pourraient être traités pour les futurs travaux.

Chapitre 2 - Revue de littérature des méthodes d'optimisation et de gestion

Ce chapitre présente l'état de l'art sur les méthodes d'optimisation et de gestion appliquées dans les MG. Dans la section 2.1, les méthodes d'optimisation seront présentées et les détails de l'algorithme à essaims particulaire (PSO) seront fournis, suivis d'une revue de littérature des méthodes de gestion hors ligne et en temps réel dans la section 2.2. Un aperçu des différentes stratégies de gestion coopérative et distribuée sera présenté dans la section 2.3. Les analyses de l'état de l'art seront examinées à la section 2.4. La section 2.5 donnera le résumé du chapitre.

2.1 Méthodes d'optimisation

Lorsqu'on veut résoudre un problème d'optimisation, on recherche la meilleure solution possible à ce problème, c'est-à-dire l'optimum global. Cependant, il peut exister des solutions intermédiaires, qui sont également des optimums, mais uniquement pour un sous-espace restreint de l'espace de recherche : on parle alors d'optimums locaux.

Contrairement aux méthodes analytiques exactes utilisées pour résoudre les problèmes d'optimisation, qui garantissent une solution optimale, les méthodes heuristiques tentent de fournir une solution suffisamment bonne, qui n'est pas nécessairement l'optimum global. Les méthodes d'optimisation peuvent être classées en deux catégories: méthodes classiques et d'intelligence artificielle, comme représentées au tableau 2-1.

Tableau 2-1 Classification des méthodes d'optimisation

Méthode classique	Méthode d'intelligence artificielle
Programmation linéaire Programmation non linéaire Méthode de Newton-Raphson Programmation quadratique Méthode de points intérieurs	Réseau de neurones artificiels (ANN) Logique floue (FL) Algorithme génétique (GA) Programmation évolutionniste (EP) Algorithme de colonies de fourmis (ACO) Recuit simulé (SA) Algorithme à évolution différentielle (DE) Optimisation de la recherche de nourriture bactérienne Algorithme de colonie d'abeilles artificielles (ABC) PSO

❖ Algorithme PSO

Le PSO est une technique d'optimisation métaheuristique, qui a été introduite par Kennedy et Eberhart en 1995 [3]. Le PSO est basé sur le comportement social des oiseaux. Un essaim est composé d'un certain nombre de particules. Chaque particule de l'essaim est une solution candidate au problème dans l'espace de recherche (D) à une position donnée (X) et avec une vitesse particulière (V). Chaque particule a une valeur de fitness unique qui est évaluée par la fonction de fitness. Pbest est la meilleure position locale qui a été trouvée

par chaque particule à chaque itération. Gbest est la meilleure position globale qui a été obtenue par n'importe quelle particule de l'essaim après toutes les itérations.

Il existe trois paramètres qui influencent les performances de l'algorithme PSO tels que le poids d'inertie (w), les coefficients d'accélération (c_1 et c_2) et la vitesse maximale (V_{\max}). Le rôle de w est d'équilibrer les explorations locales et globales. Une valeur de w élevée permet une meilleure recherche globale, tandis qu'une faible valeur permet une meilleure recherche locale. La valeur de w peut changer au cours du processus d'optimisation afin d'obtenir un meilleur résultat. Par conséquent, des approches auto-adaptatives qui modifient la valeur de w pendant la procédure de recherche sont recommandées dans la littérature.

Les coefficients d'accélération (c_1 et c_2) déterminent l'influence dans le mouvement d'une particule de Pbest et Gbest. c_1 et c_2 guident les particules à se déplacer vers Pbest et Gbest, respectivement. Les petites valeurs de c_1 et c_2 peuvent limiter les mouvements des particules vers une solution satisfaisante. Cependant, les valeurs élevées peuvent conduire les particules à s'éloigner de la solution.

La vitesse (vélocité) des particules est généralement limitée dans une plage spécifiée (V_{\max}) afin d'empêcher les particules de s'éloigner de l'espace de recherche. Si V_{\max} est trop petite, les particules peuvent seulement explorer le meilleur local, alors que si V_{\max} est trop grande, les particules peuvent dépasser la solution satisfaisante.

Certaines versions de l'algorithme PSO sont résumées comme suit [4] :

- Modification du PSO: le PSO à comportement quantique, le PSO bare-bones, le PSO chaotique, le PSO combiné avec la FL, le PSO avec le coefficient

d'accélération variable, le PSO basé sur l'opposition, la version améliorée du PSO, la version adaptative du PSO, le PSO avec la mutation, etc.

- Combinaison du PSO avec d'autres méthodes métaheuristiques (PSO hybride): le PSO avec l'ANN, le GA, l'EP, la FL, la DP, le DE, l'ACO, le SA, l'ABC, le système immunitaire artificiel, la recherche tabou, la recherche de l'harmonie, etc.
- Extension du PSO: optimisation multi-objective, contrainte, combinatoire, discrète (binaire et entière), etc.

❖ **PSO version continue**

Dans les applications du PSO en temps réel, le calcul de toutes les itérations doit être effectué à chaque pas de temps d'échantillonnage.

Les différentes étapes du PSO en temps réel peuvent être résumées comme suit :

Étape 1: Définir les paramètres d'optimisation telle que la valeur de w , c_1 , c_2 , V , D , le nombre de particules (N), et le nombre maximal d'itérations (k_{\max}).

Étape 2: Générer les nombres aléatoires représentant la position et la vitesse. La position de la particule est représentée par le vecteur $X = [X_{1D}, X_{2D} \dots X_{ND}]$. La vitesse de cette particule est représentée par le vecteur $V = [V_{1D}, V_{2D} \dots V_{ND}]$.

Étape 3: Déterminer la meilleure position locale P_{best} .

Étape 4: Évaluer la fonction objective.

Étape 5: Déterminer la meilleure position globale G_{best} .

Étape 6: Mettre à jour la vitesse et la position de la particule.

$$V_i^{k+1} = w \cdot V_i^k + c_1 \cdot r_1 \cdot (P_{\text{best}} - X_i) + c_2 \cdot r_2 \cdot (G_{\text{best}} - X_i) \quad (2-1)$$

$$X_i^{k+1} = X_i^k + V_i^{k+1} \quad (2-2)$$

Où r_1 et r_2 sont les nombres aléatoires compris entre 0 et 1.

Étape 7: Réévaluer la fonction objectif.

Étape 8: Mettre à jour la meilleure position locale Pbest.

Si $F_i^{k+1} < F_i^k$ alors $Pbest_i^{k+1} = X_i^{k+1}$, sinon $Pbest_i^{k+1} = Pbest_i^k$.

Étape 9: Mettre à jour la meilleure position globale Gbest.

Si $F_i^{k+1} < F_i^k$ alors $Gbest_i^{k+1} = Pbest_i^{k+1}$, sinon $Gbest_i^{k+1} = Gbest_i^k$

Étape 10: Répéter ce processus jusqu'à ce que le nombre maximal d'itérations soit atteint, et répéter les étapes 2 à 9 jusqu'à ce que la durée d'échantillonnage maximale soit atteinte.

Dans les équations ci-dessus, F est la fonction de fitness, k est l'indice d'itération, i est l'indice des particules.

Dans ce travail, nous avons appliqué la méthode de poids d'inertie décroissante linéaire (linear decreasing inertia weight) [5, 6] et le facteur de constriction [7].

$$w = w_{\max} - k \cdot \frac{(w_{\max} - w_{\min})}{k_{\max}} \quad (2-3)$$

$$\phi = \frac{2}{|2 - c - \sqrt{c^2 - 4c}|} \quad (2-4)$$

où w_{\min} et w_{\max} sont les bornes minimale et maximale de l'inertie, respectivement. ϕ est le facteur de constriction, et c est une constante. Nous avons $c = c_1 + c_2$ et $c > 4$.

La formule de la mise à jour de la vitesse exprimée dans l'équation (2-1) devient [8, 9]:

$$V_i^{k+1} = \phi \cdot (w \cdot V_i^k + c_1 \cdot r_1 \cdot (P_{best} - X_i) + c_2 \cdot r_2 \cdot (G_{best} - X_i)) \quad (2-5)$$

Le processus du PSO pour une simple période d'échantillonnage est représenté sur la figure 2.1.

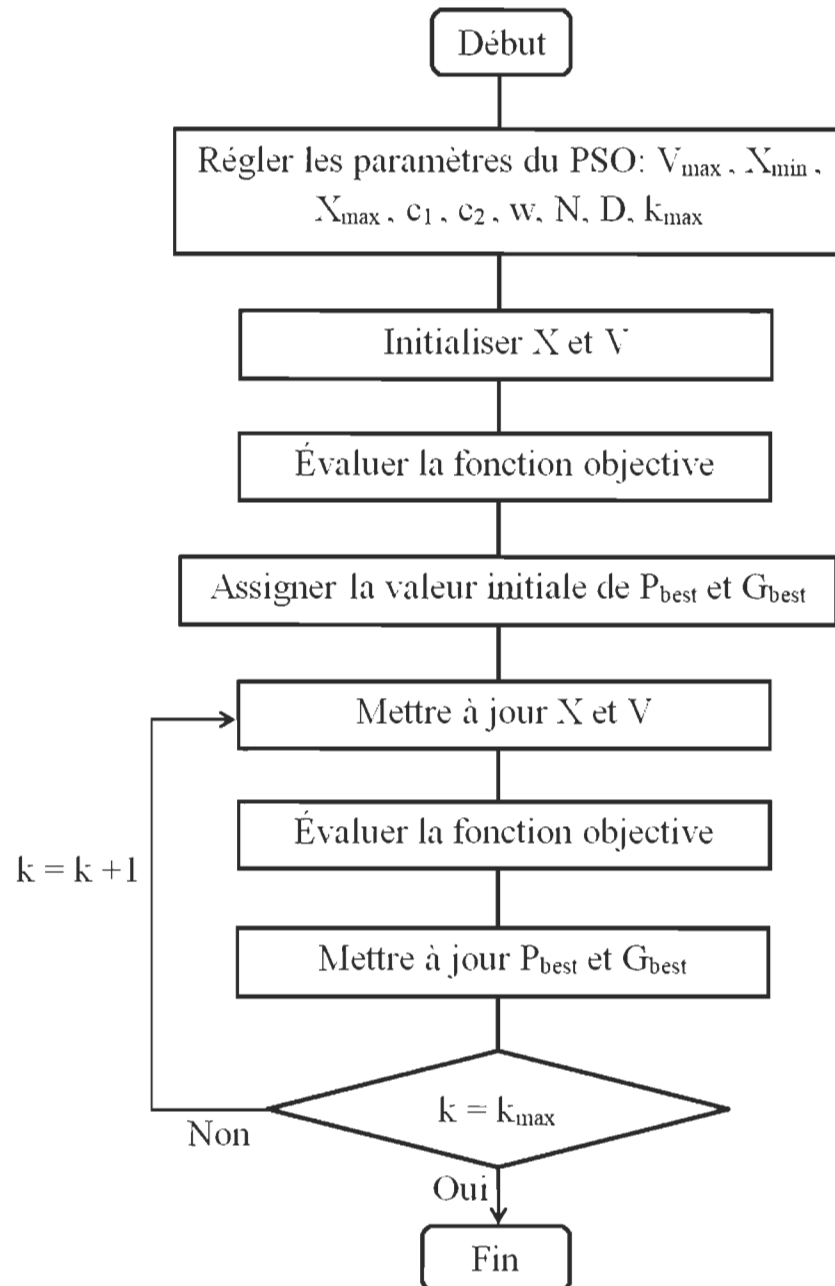


Figure 2.1 Procédure de l'algorithme PSO

❖ PSO version binaire

Pour la version binaire du PSO, la particule représente la position dans l'espace binaire et le vecteur de position des particules ne peut contenir que des valeurs binaires de 0 ou 1. L'équation de la mise à jour de la vitesse est identique à celle utilisée dans la version classique (continue). L'équation pour mettre à jour la position de la particule est:

$$x_i^k = \begin{cases} 1, & \text{si } l_i^k < s_i^k \\ 0, & \text{sinon} \end{cases} \quad (2-6)$$

où l_i^k est un nombre aléatoire compris entre 0 et 1 et s_i^k est la fonction sigmoïde ($s_i^k = \frac{1}{1+e^{-v_i^k}}$). La vitesse V_i^k est limitée dans une plage $[-V_{\max}, V_{\max}]$, V_{\max} est supposée égale à 5.

❖ Multi agent PSO (MAPSO)

Dans le MAPSO, un agent représente non seulement une solution candidate au problème d'optimisation, mais aussi une particule de l'algorithme PSO. Tout d'abord, un environnement de type treillis est construit, chaque agent étant fixé sur un point de treillis. Chaque agent est en concurrence et coopère avec ses voisins, et il peut également utiliser les connaissances pour obtenir une solution optimale de haute qualité par auto-apprentissage [10]. En utilisant le mécanisme d'évolution du PSO, il peut accélérer le transfert d'informations entre les agents [11].

- Objectif de chaque agent: un agent ∂ représente une solution candidate au problème d'optimisation en cours et est une particule du PSO. Par conséquent, l'agent ∂ a une valeur de fitness liée au problème d'optimisation.

- Définition d'un environnement: Dans un système multi agent, tous les agents vivent dans un environnement. Un environnement est organisé comme une structure en forme de réseau, comme illustré sur la figure 2.2. Dans l'environnement L, chaque agent est fixé sur un point de treillis et chaque cercle représente un agent; les données dans le cercle représentent sa position dans l'environnement L. En raison de la représentation d'une particule dans le PSO, chaque agent de sa base de données contient deux informations, à savoir la vitesse actuelle de la particule et ses coordonnées dans l'espace de recherche. La taille de L est égale à Lsize x Lsize, où Lsize est un entier. La taille est également le nombre total de particules pour le PSO.

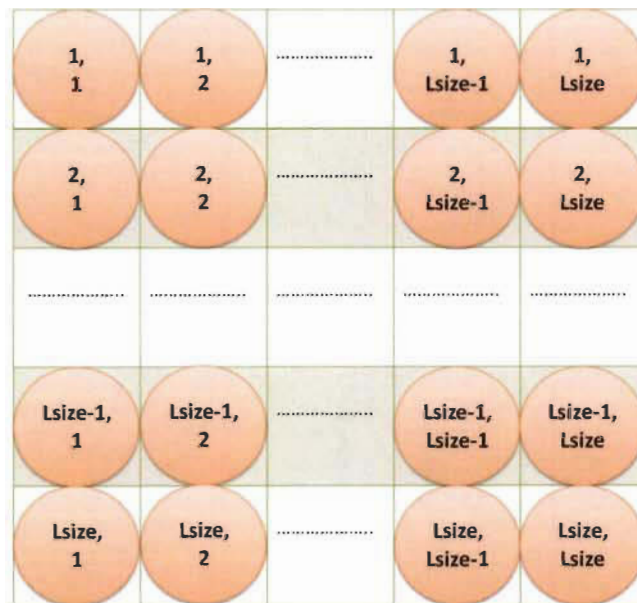


Figure 2.2 Structure de l'algorithme MAPSO

- Définition de l'environnement local: Étant donné que chaque agent ne peut que détecter son environnement local, la définition de l'environnement local est très

importante. On suppose que l'agent ∂ situé au (i, j) est représenté par $\partial_{i,j}$ ($i, j = 1, 2, \dots, Lsize$), puis les voisins de $\partial_{i,j}$, $N_{i,j}$, sont définis comme suit :

$$N_{i,j} = \{\partial_{i^1,j}, \partial_{i,j^1}, \partial_{i^2,j}, \partial_{i,j^2}\} \quad (2-7)$$

Avec

$$i^1 = \begin{cases} i - 1 & i \neq 1 \\ Lsize & i = 1 \end{cases} \quad (2-8)$$

$$j^1 = \begin{cases} j - 1 & j \neq 1 \\ Lsize & j = 1 \end{cases} \quad (2-9)$$

$$i^2 = \begin{cases} i + 1 & i \neq Lsize \\ 1 & i = Lsize \end{cases} \quad (2-10)$$

$$j^2 = \begin{cases} j + 1 & j \neq Lsize \\ 1 & j = Lsize \end{cases} \quad (2-11)$$

À partir de l'équation (2-7), chaque agent possède quatre voisins qui forment un petit environnement local.

- Stratégies comportementales pour les agents: Chaque agent est d'abord en concurrence et coopère avec ses voisins pour diffuser ses informations utiles à l'ensemble de l'environnement et il peut également utiliser le mécanisme d'évolution du PSO et ses connaissances.

La figure 2.3 montre la relation interactive entre l'environnement global et local. Les agents (ou particules) sont alloués dans l'environnement global avec leurs coordonnées uniques. Ils rivalisent et coopèrent avec leurs voisins pour accélérer la convergence et empêcher le piégeage par les optimums locaux en apprenant du partage d'informations à

chaque itération. De plus, une solution optimale de haute qualité peut également être mise à jour à partir d'une expérience antérieure d'auto-apprentissage.

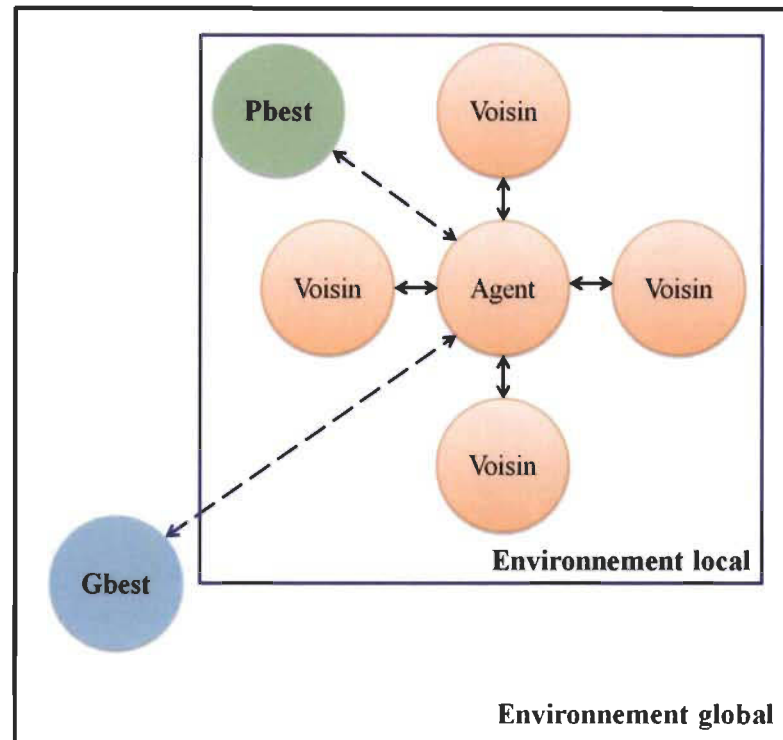


Figure 2.3 Communication interactive d'un agent

❖ Analyse des performances de l'algorithme

L'évaluation des performances de l'algorithme est généralement recommandée pour tous les problèmes d'optimisation. Nous devrions être en mesure de démontrer que l'algorithme sélectionné fournit une meilleure solution qui est plus rapide que les autres algorithmes. Ici, nous fournissons un aperçu de l'analyse des performances:

- Efficacité du calcul

L'efficacité du calcul consiste en l'effort de calcul et la qualité de la solution [12].

- Effort de calcul: Ceci correspond au temps requis pour que l'algorithme converge vers une solution optimale. Les paramètres qui influencent l'effort de calcul du PSO sont la taille de l'essaim (dimension et nombre de particules) et le nombre d'itérations. L'effort de calcul peut également se référer à divers termes tels que le temps pour atteindre la solution optimale, le temps pour calculer chaque itération et le temps total d'exécution (ou le temps pour calculer toutes les itérations).

- Qualité de la solution: la qualité de la solution fait référence à la proximité de la solution à la solution optimale [12]. Si la solution optimale est inconnue, il est difficile d'évaluer la qualité de la solution. À cet égard, la comparaison avec une solution publiée ou/et avec une solution qui a été obtenue par d'autres techniques est généralement requise.

- Robustesse

La robustesse est un critère important pour évaluer les performances d'un algorithme. Il se réfère à la capacité d'un algorithme à atteindre une solution optimale pour toute instance de divers problèmes [12] ou le même problème sous différentes conditions. Un algorithme robuste doit également être relativement insensible aux valeurs des paramètres. Lorsque les paramètres sont sélectionnés, la mesure de la sensibilité aux petits changements de ces paramètres est utile afin d'étudier la robustesse.

- La flexibilité

Le PSO est une méthode flexible qui peut résoudre tous les problèmes d'optimisation complexes. De nombreuses définitions sont utilisées pour définir la flexibilité. Dans ce travail, nous définissons la flexibilité comme l'adaptabilité de l'algorithme, car il peut

automatiquement s'ajuster et s'adapter afin de tenir compte des incertitudes et de générer les meilleures solutions possibles.

L'implémentation peut influencer l'effort de calcul de l'algorithme. Ainsi, le choix du langage de programmation, la bibliothèque et le compilateur jouent un rôle significatif dans l'amélioration des performances d'optimisation, notamment en termes d'effort de calcul. De plus, les caractéristiques de l'ordinateur (telles que le processeur et la RAM) et le système d'exploitation sont les critères importants pour effectuer une variété de tâches avec des performances de calcul élevées. Nous devons analyser différents choix et identifier les solutions qui répondent mieux aux exigences. En même temps, nous devons identifier les ressources disponibles afin de résoudre efficacement le problème d'optimisation.

❖ **Application du PSO dans la planification et la gestion d'énergie**

Le PSO est l'un des algorithmes les plus utilisés dans la planification et la gestion d'énergie dans les MG. Dans [13], les auteurs ont appliqué le PSO pour la planification du MG. Les performances du PSO sont comparées à celles d'autres algorithmes, tels que le GA, l'algorithme de pollinisation des fleurs (flower pollination algorithm) et l'optimiseur de fourmi lion (ant lion optimizer), etc. La planification optimale des MG est traitée dans [14], dans lequel la valeur à risque (Value at risk : VaR) a été utilisée pour l'évaluation des risques. Le problème d'optimisation a été résolu par la version modifiée du PSO dans le but de maximiser le profit quotidien. Une autre implémentation du PSO a été réalisée dans [15] pour résoudre le problème de gestion de l'énergie dans le MG. Cette étude a proposé la combinaison du PSO avec du GA afin d'améliorer la convergence de la solution. Dans [16], la version modifiée du PSO a été mise en œuvre pour la répartition optimale de l'énergie

dans les MG. De plus, les auteurs ont comparé l'efficacité de la version modifiée du PSO avec celle de l'ACO, l'ABC et la version standard du PSO, etc. La version modifiée du PSO a également été introduite dans [17] pour optimiser la capacité de chaque système de stockage d'énergie (ESS) et la fluctuation de puissance dans le MG. Dans [18], la version modifiée du PSO a été utilisée afin de définir la répartition optimale de la puissance entre les composants du MG sous l'incertitude du profil de charge. Les performances du PSO proposé ont été comparées à celles des autres versions du PSO et d'autres algorithmes. Les auteurs de [19] ont utilisé le PSO pour résoudre l'optimisation multi-objective des MG. L'objectif est de trouver le meilleur compromis entre le coût d'exploitation et la fiabilité-disponibilité. Les résultats ont montré les meilleures performances du PSO par rapport au GA. Un système de gestion d'énergie pour le MG a été proposé dans [20] afin de réduire le coût d'exploitation. Le modèle d'optimisation a été résolu efficacement par la version modifiée du PSO.

Dans [21, 22], le PSO a été implémenté afin d'optimiser le fonctionnement du MG tout en comparant sa performance avec le GA. Les résultats montrent que le PSO fournit les meilleures performances de convergence. Référence [23] utilise le PSO afin de minimiser les coûts d'exploitation du MG. Les auteurs montrent l'efficacité du PSO versus d'autres algorithmes implémentés dans la littérature. La version classique du PSO et la version hybride du PSO (hybride PSO-pattern search) ont été appliquées dans [24] afin d'optimiser la conception et le fonctionnement du MG. Ces deux versions peuvent efficacement atteindre le résultat optimal. Le PSO à convergence garantie et de mutation gaussienne (Guaranteed convergence Particle Swarm Optimization with Gaussian Mutation) a été décrite dans [25] pour minimiser l'investissement et les coûts de production. Le rôle de la

mutation gaussienne et la convergence garantie est d'assurer la précision des résultats. L'algorithme proposé est plus performant comparant à la version standard du PSO et du GA. Les auteurs de [26] proposent le PSO auto-adaptative floue (Fuzzy Self Adaptive PSO) afin de minimiser le coût total d'exploitation et les émissions. Pour évaluer les performances de la méthode proposée, les auteurs comparent les résultats obtenus avec ceux de la version classique du PSO et du GA. Une nouvelle version du PSO, nommée (Weighted improved crazy PSO), est présentée dans [27] afin de trouver le compromis entre le coût d'opération et l'émission sous différents scénarios stochastiques. L'algorithme proposé garantit la solution optimale et la rapidité de la convergence en comparant avec la version classique du PSO, la version inertie améliorée du PSO (weight improved PSO) et le crazy PSO.

2.2 Méthodes de gestion hors ligne et en temps réel

L'optimisation de coût d'énergie dans les MG peut être classifiée en deux catégories : l'optimisation hors ligne et l'optimisation en temps réel. L'optimisation hors ligne est fondée sur une connaissance à priori des conditions météo et de profil de charge. Elle permet d'évaluer les performances de la stratégie de gestion en temps réel, puisqu'elle détermine la solution optimale théorique.

❖ Méthodes de gestion hors ligne

Plusieurs travaux sur d'optimisation ont été formulés hors-ligne sous forme d'optimisation déterministe [22, 28-33]. Cette méthode est relativement simple et facile à mettre en œuvre. Cependant, les performances du système dépendent de l'erreur des paramètres du modèle et l'incertitude des paramètres d'entrée.

L'article [34] propose une technique d'optimisation combinée, nommée Enhanced Velocity DE-PSO, afin de résoudre le problème stochastique de la gestion de l'énergie du MG. L'objectif est de réduire les coûts d'exploitation et de maximiser les revenus sous 100 scénarios des rayonnements solaires, du profil de charge, du prix d'énergie, etc. D'autres algorithmes sont proposés dans [35-37] dans le contexte similaire, c'est-à-dire de résoudre le problème de gestion stochastique. Les auteurs de [38] ont proposé un modèle de planification pour un système distribué qui contient plusieurs générateurs tel que les centrales hydroélectriques, l'éolien (WT) et le ESS. L'approche d'optimisation robuste-stochastique à deux niveaux a été présentée pour minimiser le coût total d'exploitation prévu sous plusieurs scénarios d'afflux d'eau en grappes et le pire cas de l'ensemble d'incertitudes de production d'énergie éolienne. Les auteurs de [39] ont proposé un modèle de planification robuste à deux niveaux pour minimiser le coût d'exploitation des MG. Dans ce modèle, les variables d'état telles que l'état ON/OFF du diesel (DG) et les limites de fluctuation de puissance des lignes de raccordement sont prises comme variables du premier niveau et la puissance de sortie des composants sont les variables du deuxième niveau, ce qui garantit une solution optimale et réalisable pour tous les scénarios dans l'ensemble d'incertitudes.

L'étude [40] propose une approche robuste-stochastique à deux niveaux pour minimiser le coût d'opération journalier du MG face aux incertitudes de la production et la demande. Ce modèle optimise les variables binaires du DG et du convertisseur bidirectionnel au premier niveau tandis que le deuxième niveau optimise la puissance et l'état de fonctionnement de chaque composant. Le problème d'optimisation a été présenté sous forme de problème min-max-min et est extrêmement difficile à résoudre. Cependant, les

auteurs montrent que le coût d'exploitation journalier dans le pire des cas a été minimisé. Dans [41], une méthode d'optimisation robuste adaptative min-max-min a été introduite afin d'aborder la planification du MG, compte tenu des incertitudes associées aux RES, la demande et le prix d'électricité du réseau. Au premier niveau, les décisions d'engagement des sources de production (unit commitment : UC) sont prises avant la prise en compte des incertitudes. Au deuxième niveau, le pire cas face aux paramètres incertains a été déterminé. Au troisième niveau, les décisions de recours ont été prises après la présence des incertitudes. Les résultats montrent que le modèle proposé entraîne une réduction des coûts d'opération. L'article [42] fournit une nouvelle approche à deux étapes pour résoudre le problème d'UC des générateurs conventionnels et le WT en tenant compte de l'incertitude. Les variables de décision sont divisées en deux groupes. Le premier groupe se compose des variables binaires représentant l'état ON/OFF de chaque composant. Les variables de décision du deuxième groupe servent à déterminer la puissance optimale des sources d'énergie conventionnelle. Cette approche permet de trouver le plan optimal d'UC qui fonctionne efficacement en termes de coût d'exploitation prévu et du pire cas du système.

Le modèle d'optimisation robuste de distribution à contraintes aléatoires (distributionally robust chance-constrained programming : DRCCP) pour la planification du MG a été développé dans [43] en tenant compte de l'incertitude de l'énergie éolienne. Les objectifs sont de chercher des revenus provenant du marché de l'électricité, la pénalité causée par l'énergie éolienne et le coût de dégradation de la batterie (Battery energy storage system : BESS). Le modèle DRCCP est basé sur le DRO afin de transformer le problème de la planification sous contrainte probabiliste (chance-constrained) en un problème de cône du second ordre (second order cone programming : SOCP).

❖ Méthodes de gestion hiérarchisée basée sur les optimisations hors ligne et en temps réel

De nombreux travaux de recherche ont été menés sur la gestion de l'énergie en temps réel dans les MG. Il est possible de réaliser la gestion en temps réels à un seul niveau en résolvant le problème à chaque pas de temps basé sur les horizons de prévision glissante. Cependant, ces méthodes sont plus robustes et efficaces en les combinant avec la gestion hors-ligne, afin de former la méthode de gestion hiérarchisée à deux niveaux. Au niveau inférieur, la planification journalière a été formulée. Au niveau inférieur, l'optimisation en temps réel a été exécutée afin d'ajuster la puissance de sortie des composants. La stratégie d'optimisation à l'horizon glissant, nommée la commande prédictive (Model predictive control : MPC) a été utilisée à cette étape. Le principe de la gestion hiérarchisée basée sur la MPC est représenté sur la figure 2.4.




Figure 2.4 Structure du modèle de gestion hiérarchisé basée sur la MPC

Un modèle d'optimisation multi-niveaux a été formulé dans [44] pour le fonctionnement optimal des MG. Ce modèle inclut l'optimisation stochastique et robuste qui représente la structure de la planification et l'échange d'énergie en temps réel. Les MG sont exploités en mode coopératif pour atteindre le coût d'exploitation le plus bas via des transactions énergétiques avec le réseau principal. Dans [45], une structure à deux niveaux a été développée afin de coordonner la planification et le fonctionnement en temps réel du MG. L'optimisation en temps réel intègre l'optimisation glissante et la MPC dans laquelle la précision a été améliorée. Dans l'étude [46], une stratégie à deux niveaux combinée de la programmation stochastique et l'optimisation glissante a été proposée pour la gestion de l'énergie dans les MG face à l'incertitude. Avec la stratégie stochastique, la planification a été dérivée afin de minimiser le coût d'opération en impliquant le risque de l'impact de l'incertitude. Avec l'optimisation glissante, l'incertitude au sein du MG a été compensée par une boucle de retour avec les informations de prévision mises à jour. Les auteurs de [47] présentent une méthode d'optimisation hiérarchisée à deux niveaux pour le système de gestion de l'énergie du MG communautaire dans un environnement de réseau intelligent. Le niveau inférieur se concentre sur un MG individuel et le niveau supérieur est responsable de la gestion des MG et des dispositifs du MG communautaire. Le niveau inférieur optimise la puissance des générateurs, du ESS et la puissance échangée avec le réseau. Les résultats du niveau inférieur sont transférés au niveau supérieur en tant que contraintes. Le niveau supérieur prend des décisions concernant les puissances des dispositifs du MG communautaire et la puissance échangée entre les réseaux de distribution sur la base des résultats du niveau inférieur. La référence [48] présente une méthode de gestion prédictive à deux niveaux pour minimiser le coût total d'exploitation du MG. Le premier niveau résout

le problème d'UC via une optimisation déterministe prédictive. Le modèle d'UC proposé est capable de mettre à jour son plan sur un horizon de trois heures. Le deuxième niveau reçoit la référence obtenue au premier niveau et effectue une mise à jour en temps réel pour la répartition d'énergie de tous les composants. Les résultats montrent que la méthode proposée permet aux DG de réduire la consommation du carburant jusqu'à 15%. Dans [49], le modèle de la planification horaire (hour-ahead scheduling) et de la planification en temps réel ont été développés. La planification horaire a été utilisée pour relier la planification d'un jour à l'avance et la planification en temps réel. Ce modèle a été exécuté toutes les heures afin de fournir une consigne pour l'heure suivante avec une résolution temporelle de 15 min. La planification en temps réel a été effectuée toutes les minutes pour éliminer le déséquilibre de la puissance dû aux incertitudes des sources d'énergie renouvelable (Renewable energy sources : RES) et des charges. Les résultats de la simulation révèlent que la méthode proposée est efficace afin de fournir un plan de production économique et sécuritaire. Dans [50], un modèle MPC à deux niveaux a été proposé pour minimiser le coût de fonctionnement d'un MG. Ce modèle d'optimisation à deux niveaux est résolu récursivement en se basant sur l'horizon à long terme et à court terme. Cette approche permet d'améliorer la robustesse contre les incertitudes de la charge et le photovoltaïque (PV) tout en minimisant le coût de fonctionnement. Les auteurs de [51] ont proposé un algorithme d'optimisation à deux étapes pour minimiser le coût d'exploitation total et les émissions de gaz d'un MG. La première étape consiste à l'optimisation glissante basée sur la MPC pour la planification. La deuxième étape comprend la boucle de correction afin d'ajuster la répartition d'énergie. Cette boucle utilise la puissance du réseau, la batterie et le

DG pour compenser l'erreur de prévision et les re-planifie afin d'obtenir le coût d'opération le plus bas.

Le modèle de gestion hiérarchisée basé sur l'optimisation robuste et stochastique a été introduit dans la littérature. L'article [52] présente une approche stochastique à deux niveaux pour minimiser la valeur attendue et la valeur conditionnelle au risque de coût d'opération. Les incertitudes du prix d'énergie, de la charge, du PV et de la température ambiante sont prises en compte dans le modèle. La première étape consiste à gérer la stochasticité du prix d'énergie d'un jour à l'avance. La deuxième étape tient compte des incertitudes de la puissance PV, de la charge et de la température ambiante en temps réel. L'étude [53] présente un modèle robuste-stochastique à deux niveaux pour une planification optimale des MG afin de gérer les incertitudes. La vitesse du vent, le rayonnement solaire et la charge sont modélisés en utilisant une approche basée sur des scénarios tandis que le prix d'énergie est formulé sur la base de la méthode robuste. Les auteurs de [54] proposent un modèle robuste-stochastique pour la gestion d'énergie du MG considérant les véhicules électriques rechargeables. Comme le prix du marché en temps réel est imprévisible, son incertitude est gérée via la programmation robuste, tandis que l'incertitude associée à d'autres paramètres est envisagée via la programmation stochastique. Le travail [55] propose un modèle d'optimisation robuste-stochastique pour les MG. Les incertitudes sont représentées sous des scénarios, dont la fonction objectif est formulée sur la base d'une optimisation stochastique et d'une valeur à risque conditionnelle. Les incertitudes des RES sont représentées sous l'ensemble d'incertitudes, les contraintes opérationnelles sont établies sur la base d'une optimisation robuste, afin de garantir un fonctionnement sécuritaire et stable dans les pires cas de l'ensemble d'incertitudes. Dans

l'article [56], un modèle de planification et de fonctionnement en temps réel pour le MG a été développé. Dans un premier temps, le modèle de planification basé sur l'optimisation robuste de distribution (Distributionally robust optimization : DRO) a été conçu. Les ensembles d'incertitudes sont construits à partir des moyennes et des déviations des incertitudes. La planification fournit le résultat dans le pire des cas et améliore donc la conservabilité en garantissant la robustesse. Ensuite, une optimisation glissante à plusieurs échelles de temps a été développée pour la répartition de la puissance en temps réel. Un modèle basé sur l'énergie transactive a été conçu dans [57] pour la gestion coordonnée de l'énergie entre le réseau haute tension et des MG via le système de distribution. Chaque MG détermine la puissance optimale des composants et l'écart entre la demande et la production sera compensé par l'échange de puissance des MG via le système de distribution. Cependant, le système de distribution est connecté au système à haute tension. L'algorithme basé sur le DRO a été développé afin fournir une solution robuste et sans être trop conservateur, face à l'incertitude. Ce modèle DRO gère le problème de planification de l'énergie transactive entre le réseau haute tension et des MG. Dans le fonctionnement en temps réel, la déviation de l'échange de puissance planifiée est réglée en fonction du prix d'énergie en temps réel sur le marché. Les auteurs [58] combinent l'approche robuste et stochastique et présentent un modèle DRO développé sur la base des données historiques connues. Dans la première étape du modèle, la fonction objectif comprend le coût de démarrage/arrêt des sources et le coût associé au scénario de prévision de l'énergie éolienne, ce qui permet une stratégie de planification plus économique. Le rôle de cette étape est de définir l'état ON/OFF des différents composants. Dans la deuxième étape du modèle, la décision de l'opération en temps réel a été menée. L'article [59] propose un

modèle à contrainte de distribution robuste basé sur l'approche d'énergie transactive pour la planification optimale des MG électrique et à gaz. La planification optimale des ressources distribuées a été réalisée afin de maximiser les bénéfices sur les marchés de l'électricité et du gaz d'un jour à l'avance tout en minimisant les coûts d'importation d'énergie. Ce modèle est capable de faire face aux incertitudes liées aux RES et au marché de l'énergie dans les MG.

2.3 Méthodes de gestion coopérative et distribuée

Les techniques de coordination existantes pour optimiser le partage de puissance dans les MG peuvent être classées en deux catégories: la technique centralisée et décentralisée. Dans la technique centralisée, le calcul des points de consigne optimaux pour chaque MG incombe à une entité centrale, qui repose souvent sur une communication étendue avec les sous-systèmes (c'est-à-dire les bus locaux). La technique décentralisée ou distribuée est une technique qui impose l'implémentation d'un contrôleur local pour chaque MG. Le contrôleur local peut améliorer considérablement les performances de l'ensemble du système, car le point de défaillance unique n'est plus un problème. La structure de la technique distribuée est illustrée sur la figure 2.5. Dans ce cas, il existe une liaison de communication bidirectionnelle entre les MG voisins, limitant le transfert d'informations dans l'ensemble du système composé de multiple MG.




Figure 2.5 Structure du modèle centralisé et décentralisé

Dans l'article [60], une approche collaborative basée sur l'optimisation robuste adaptative à deux niveaux a été proposée pour la planification des MG. Ce modèle caractérise les décisions d'UC au niveau supérieur et les décisions de fonctionnement continu au niveau inférieur. L'objectif est de rassurer le fonctionnement coordonné entre les MG afin de réduire les coûts d'exploitation et les échanges d'énergie avec le réseau. L'approche proposée a été comparée à l'approche non collaborative dans laquelle les transactions énergétiques entre les MG ne sont pas autorisées. Les auteurs de [61] proposent un modèle de planification pour le fonctionnement coopératif des MG, où la coalition entre chaque MG permet d'obtenir l'échange d'énergie avec le réseau. Ce modèle vise à maximiser le profit attendu de chaque MG. Dans ce modèle, l'excès de la production dans un MG peut être transféré aux MG voisins en déficit de puissance. Les intermittences dans les MG sont capturées via des scénarios et le modèle d'optimisation a été résolu par le PSO. Dans [62], un modèle stochastique et probabiliste des ressources énergétiques et de la

charge de chaque MG a été conçu afin de déterminer le fonctionnement économique de chaque MG fonctionnant en coopération avec d'autres MG. L'article [63] décrit l'algorithme de gestion décentralisée pour les MG couplés. Les informations et les stratégies coordonnées entre les MG permettent de réduire le coût total d'exploitation, améliorer l'efficacité de l'utilisation du stockage distribué et réduire la complexité du fonctionnement du réseau de distribution. Le problème de gestion optimale des MG a été modélisé basé sur le processus de décision de Markov décentralisé et partiellement observable, ainsi que la DP a été utilisée afin de résoudre ce problème. La référence [64] a conçu un modèle de coopération pour les échanges d'énergie entre les MG et les MG avec le réseau principal. Les auteurs ont souligné la pertinence de l'opération des MG en mode coordination permettant de réduire les coûts d'exploitation.

Les auteurs de [65] ont formulé les approches non coopératives et coopératives pour la répartition optimale de l'énergie et le dimensionnement optimal des BESS dans les MG. L'étude a montré que la participation de la BESS au fonctionnement du MG et la coopération entre les MG peuvent réduire les coûts d'exploitation. L'article [66] propose la répartition optimale coordonnée des ESS dans les MG, dans lequel ces MG peuvent partager leur stockage d'énergie afin de minimiser le coût de l'électricité. Cette méthode permet aux MG de partager ses RES et ses BESS et d'interagir collectivement avec le réseau. Le problème d'optimisation multiobjectif a été formulé afin d'obtenir les plans optimaux de charge/décharge des ESS basé sur l'optimisation glissante. La répartition optimale coordonnée des énergies stockées avec les transactions énergétiques locales peut réduire considérablement les coûts d'électricité des MG par rapport aux cas dans lesquels ils interagissent avec le réseau électrique sur une base individuelle. La référence [67] a

proposé une stratégie de gestion distribuée pour les MG. Le problème a été formulé sous forme de problème stochastique à deux niveaux, dont l'opérateur du réseau de distribution au niveau supérieur et les MG au niveau inférieur. Chaque niveau se compose de deux étapes. La première étape détermine les points de consigne de la production en fonction des prévisions et la deuxième étape ajuste le plan de production en fonction des scénarios réalisés. Les résultats montrent que le modèle proposé est plus performant que le modèle déterministe et le modèle centralisé. Les auteurs de [68] proposent une approche hiérarchique pour planifier l'échange d'énergie, le stockage et la distribution de l'énergie dans un smart grid avec un macro réseau (macrogrid) ainsi que les MG couplés. Le premier niveau gère le macro réseau tandis que le deuxième niveau contrôle chaque MG. Avec le mode coopératif, le MG est en mesure de partager sa puissance excédentaire avec d'autres MG à proximité ou avec le macro réseau. L'étude [69] propose une gestion coopérative des MG avec des opérations coordonnées de manière séquentielle afin de répartir l'effort de calcul. Il existe deux types de systèmes de gestion de l'énergie dans chaque MG: un système central et des sous-systèmes de gestion de l'énergie. Ces deux fonctionnent en coordination afin de chercher le fonctionnement économique de chaque MG. Ce processus de fonctionnement coordonné-séquentiel du système central et sous-système comprend les deux éléments suivants: 1) l'optimisation locale menée par chaque sous-système à l'échelle locale et 2) l'optimisation globale effectuée par le système central à l'échelle globale. L'article [70] propose le fonctionnement optimal des MG par un modèle coopératif de planification de l'énergie et des réserves basé sur la théorie des jeux. L'énergie et la réserve peuvent être utilisées coopérativement entre les MG. De plus, la valeur de Shapley permet de répartir les bénéfices dans le cadre de l'opération coopérative. Dans [71], les auteurs

abordent le problème de gestion de l'énergie pour deux MG fonctionnant en mode coopératif. Chaque MG se compose des RES et des ESS. Premièrement, les profils de production et de charge dans les MG sont supposés parfaitement connus à l'avance. Le problème de gestion de l'énergie est donc résolu hors ligne. La coopération entre les MG et l'utilisation des ESS peuvent aider à atténuer les intermittentes des RES. Ensuite, à partir de la solution optimale obtenue hors ligne, l'algorithme en temps réel a été introduit pour le fonctionnement coopératif des deux MG. Les auteurs de [72] proposent une approche de gestion de l'énergie à deux niveaux pour les MG, dans laquelle chaque MG optimise son coût d'exploitation, puis se coordonne avec le système central afin d'optimiser l'ensemble des MG. La gestion de chaque MG a été menée par le système de gestion locale au niveau primaire, dont le déficit/excès de l'énergie doit être envoyé au niveau secondaire. Le système de gestion centrale au niveau secondaire est responsable de la coordination globale des MG. Dans ce modèle, un minimum d'échange d'information, entre les MG et le gestionnaire du réseau de distribution, est requis. Le travail [73] étudie les interactions entre les MG autonomes et développe une stratégie pour la planification d'échange d'énergie de ces MG. Chaque MG planifie sa production, sa demande et l'échange de l'énergie avec d'autres MG à travers d'un réseau de distribution. Plus précisément, les MG en excès d'énergie peuvent échanger avec d'autres MG en déficit afin d'obtenir les avantages communs. Ce travail conçoit un mécanisme utilisant la théorie de Nash Bargaining pour encourager l'échange d'énergie et le partage équitable des bénéfices.

Dans l'article [74], le modèle coopératif basé sur la MPC a été proposé, nommé la MPC distribuée (DMPC), afin de coordonner la gestion de l'énergie dans les MG. Chaque MG est équipé d'un système de gestion de l'énergie basé sur la MPC afin de se coordonner

pour optimiser un objectif commun. L'algorithme proposé est entièrement distribué et garantit la satisfaction des contraintes, la coopération entre les MG et l'équité dans l'utilisation des ressources partagées, tout en minimisant le coût d'opération. Un autre modèle DMPC a été proposé dans [75] pour la répartition optimale de la puissance dans les MG. Chacune des entités suivantes est équipée d'un contrôleur local basé sur la MPC: le DG, la BESS et la charge. Dans cette méthode, le problème centralisé de la gestion de l'énergie des MG est converti en plusieurs problèmes capables d'interagir entre eux, et les contrôleurs MPC basés sur les sous-systèmes se coordonnent via une minimisation itérative du coût total d'opération. L'article [76] présente la gestion de l'énergie coordonnée basée sur la DMPC, où le niveau supérieur fournit une planification optimale pour l'échange d'énergie entre le gestionnaire de réseau de distribution et les MG, tandis que le niveau inférieur garantit la satisfaction entre l'offre et la demande. Afin de décrire la dynamique de l'échange d'énergie, un nouveau modèle de distribution de probabilité conditionnelle a été introduit, qui caractérise les incertitudes dans le système. L'équilibre entre l'offre et la demande est maintenu de manière économique et l'utilisation des RES a été améliorée. Les auteurs de [77] proposent un autre modèle de gestion coopératif de l'énergie basée sur la DMPC pour les MG couplés. Le MG est virtualisé sous la structure à deux niveaux afin de simplifier les interactions internes entre les sous-systèmes. Les ressources distribuées et les charges connectées à la ligne basse tension sont combinées en MG virtuel représentant le niveau supérieur. D'autres MG réels appartiennent au niveau inférieur. Dans ce cas, les transactions d'électricité entre les MG du niveau inférieur doivent passer par le niveau supérieur de manière hypothétique. En outre, le MG virtuel du niveau supérieur est responsable de l'échange d'énergie avec le réseau public, et les MG du niveau inférieur

n'ont pas l'autorisation de se connecter directement avec le réseau public. Tous les sous-systèmes se calculent en parallèle en adoptant la méthode coopérative de barrière logarithmique. Dans [78], la DMPC a été utilisée pour la gestion d'énergie éolienne (dans une zone) avec le stockage (dans une autre zone) afin de minimiser le coût d'exploitation. L'objectif principal est de permettre une coordination optimale entre la production d'énergie éolienne avec l'ESS. L'article [79] étudie plusieurs MG intelligents interconnectés et développe une stratégie efficace pour la planification et le fonctionnement de leurs composants. Chaque MG gère ses composants, tels que les ESS locaux et les niveaux de compensation de la puissance réactive, et l'échange d'énergie (avec le réseau et avec d'autres MG) en temps réel. Chaque MG vise à optimiser leurs propres performances et à tirer des avantages d'échange d'énergie. Un algorithme entièrement distribué basé sur la MPC a été proposé, de sorte que les composants des MG fonctionnent de manière autonome avec un minimum de communication. Une stratégie de gestion basée sur la DMPC pour la coopération des MG a été proposée dans [80]. Chaque MG est équipé d'un système de gestion basé sur la MPC, réagissant indirectement sur le fonctionnement optimal global des MG en résolvant leur problème d'optimisation locale. Les MG et les ressources distribuées (la cogénération ou le stockage d'énergie) sont coordonnés de manière à optimiser les sources flexibles et à atteindre un objectif commun, à savoir, minimiser l'énergie échangée avec le réseau de distribution et les coûts énergétiques globaux. La comparaison du fonctionnement des MG en mode coopératifs et non coopératifs a été menée. Les résultats montrent que l'échange d'énergie avec le réseau de distribution grâce à la coopération des MG est avantageux non seulement en termes d'économie, mais aussi pour la réduction de la quantité d'énergie échangée avec le réseau.

Une autre comparaison a été menée en appliquant la MPC centralisée. Les résultats montrent clairement que les coûts générés par la DMPC sont légèrement plus élevés (environ 5%). Cependant, il faut seulement environ deux minutes en moyenne pour obtenir une solution réalisable, tandis que le temps de résolution d'une itération de la MPC centralisée prend au moins deux heures. Dans [81], la méthode de gestion distribuée pour un fonctionnement optimal des MG a été présentée afin de minimiser le coût total d'exploitation et la dégradation de la durée de vie d'une BESS. Cette méthode vise également à définir la collaboration la plus prometteuse des MG via la DMPC. Un modèle hiérarchique basé sur la MPC a été présenté dans [82] afin d'obtenir le fonctionnement économique d'un MG par l'intégration d'une DMPC. La structure proposée a été décomposée en deux niveaux, le niveau du MG et de la charge, où la coordination entre ces deux niveaux a été établie afin d'obtenir un bénéfice maximal.

2.4 Analyses de la revue de littérature sur les méthodes de gestion

- ❖ Les approches d'optimisation hiérarchisées à deux niveaux mentionnées ci-dessus n'ont pas pris en compte les impacts des incertitudes liées à la production et la demande dans la phase de planification. L'optimisation en temps réel peut modifier les résultats optimaux du modèle déterministe de la planification. De plus, le résultat de la planification sans tenir compte des incertitudes ne peut pas garantir tous les scénarios en temps réel. Plus précisément, le modèle déterministe manque de robustesse vis-à-vis de l'incertitude.

Même si quelques approches d'optimisation robuste et stochastique pour la planification ont été introduites afin de décrire les incertitudes. L'approche stochastique

n'apporte pas de robustesse dans sa solution et nécessite la distribution exacte des scénarios, ce qui peut ne pas être possible dans de nombreux cas en pratique. D'autre part, l'approche robuste peut être trop conservatrice et mal fonctionner dans les cas habituels.

- ❖ La plupart des études menées sur la méthode de gestion coopérative et distribuée utilisent la méthode de calcul parallèle et synchronisée. Cette approche est performante en termes de qualité de la solution, mais nécessite un temps de calcul très long.
- ❖ D'autre part, nous constatons que les études susmentionnées ne prennent pas en compte le critère de maintenance des composants dans l'opération (fonctionnement) optimale. Ces études considèrent le fonctionnement et la maintenance comme deux problèmes indépendants. Cependant, les deux sont interdépendants dans la pratique.
- ❖ Enfin, nous constatons que les approches d'optimisation robuste-stochastique proposées ont été modélisées en deux niveaux sous forme de problème min-max-min qui est très difficile à résoudre et nécessitent une reformulation et une décomposition du problème.

2.5 Conclusion

Dans ce chapitre, nous avons présenté les méthodes d'optimisation utilisées pour la gestion d'énergie dans les MG. Nous avons aussi décrit le principe de l'algorithme PSO ainsi que ses différentes versions. Ensuite, nous avons présenté les méthodes d'analyse de performances de cet algorithme en vue de l'implémentation réelle. Nous avons finalement présenté les différentes méthodes et stratégies d'optimisation dans les MG, à savoir, l'optimisation déterministe, stochastique et robuste. Ainsi, les méthodes de gestion

hiérarchisées et distribuées sont analysées. Ces études seront développées et mises au point dans les chapitres suivants.

Chapitre 3 - Modèle et outil de simulation du MG

Dans ce chapitre, nous allons dans un premier temps décrire les variables d'optimisation utilisées dans l'optimisation du MG. Ensuite, nous allons présenter les modèles mathématiques simplifiés des composants ainsi que leurs principes de fonctionnement. Le chapitre fournira également les modèles économiques de ces composants. Ainsi, leurs contraintes de fonctionnement seront décrites. Enfin, les modèles et les outils mathématiques utilisés dans ce travail de thèse seront présentés.

3.1 Variables d'optimisation

La formulation des problèmes d'optimisation du MG est souvent basée sur des variables discrètes et continues. Ces variables sont utilisées pour modéliser la marche/arrêt (état ON/OFF) et la puissance de sortie des composants.

❖ Optimisation basée sur la variable continue

Dans l'optimisation continue, les variables du modèle peuvent prendre n'importe quelle valeur située dans une plage, généralement des nombres réels. Cette propriété contraste avec l'optimisation discrète, dans laquelle certaines ou toutes les variables peuvent être binaires (1 et 0) ou entières (pour lesquelles seules les valeurs entières sont autorisées).

❖ Optimisation basée sur la variable mixte discrète/continue

Dans cette partie, nous décrivons brièvement la relation entre les variables semi-continues et mixtes discrètes/continues dans l'optimisation du fonctionnement du diesel (DG).

Pour les variables mixtes discrètes/continues, on introduit une variable binaire U qui prend la valeur 1 ou 0, indiquant l'état de marche/arrêt du DG. Si le DG est en marche, c'est-à-dire que U est égale à 1, il délivre une puissance (P_{dg}) entre sa valeur minimale et maximale $[P_{dg_min}, P_{dg_max}]$; Si le DG est en arrêt, U est donc égale à 0 et P_{dg} devient nulle. Dans ce cas, U est en fait introduit comme une variable auxiliaire.

Nous pouvons décrire l'état marche/arrêt du DG uniquement par P_{dg} : le DG est en marche lorsque $P_{dg} \in [P_{dg_min}, P_{dg_max}]$, et il est en arrêt lorsque P_{dg} est nulle. Par conséquent, P_{dg} peut prendre n'importe quelle valeur de $0 \cup [P_{dg_min}, P_{dg_max}]$, P_{dg} est donc une variable semi-continue.

Dans la figure 3.1 (a)-(b), nous montrons la modélisation de la variable P_{dg} seule et P_{dg} couplée avec U . Les régions réalisables de P_{dg} sont représentées par des points rouges et des lignes rouges, et celles de U sont représentées par des points bleus. Nous pouvons voir que l'espace de recherche devient plus compliqué lorsque P_{dg} est couplée avec U .




Figure 3.1 Comparaison des zones de fonctionnement du DG

3.2 Modèles des composants

Les MG se composent généralement des sources contrôlables, non contrôlables et du système de stockage d'énergie (Energy storage system : ESS). Les sources contrôlables permettent d'ajuster rapidement leur puissance de sortie telles que les DG, des micro-turbines, des générateurs à biomasse, etc. Les sources non contrôlables, contrairement aux sources contrôlables, ne peuvent pas avoir leur puissance de sortie et leur point de réglage facilement ajustés ou contrôlés afin répondre à la variation de la charge. Ces sources d'énergie sont basées sur le soleil et le vent.

3.2.1 Éolien

Le WT se compose d'un rotor, un générateur, les pales de turbine et un entraînement ou un dispositif de couplage. Lorsque le vent souffle à travers les pales, l'air exerce des forces aérodynamiques qui font tourner les pales du rotor. Lorsque le rotor tourne, sa vitesse est modifiée pour correspondre à la vitesse de fonctionnement du générateur. La plupart des

systèmes ont une boîte de vitesses et un générateur dans une seule unité derrière les aubes de turbine.

Les principes de fonctionnement de l'éolien (WT) peuvent être décrits dans deux processus, qui sont exécutés par ses composants principaux: le rotor qui extrait l'énergie cinétique du vent qui la traverse et la convertit en couple mécanique et le système de génération, qui convertit ce couple en électricité. La puissance de sortie du WT est définie par l'équation :

$$P_{wt,i}(t) = \frac{1}{2} \rho \cdot A_i \cdot C_p(\lambda, \beta) \cdot V_s^3(t) \quad (3-1)$$

où P_{wt} est la puissance de sortie du WT, A est la surface balayée par les pales d'une éolienne (m^2), ρ est la densité d'air (1.225 kg/m^3), C_p est le coefficient de performance, λ est le rapport de vitesse de pointe, β est l'angle de calage des pales (deg), V_s est la vitesse du vent (m/s) et i est l'indice du WT.

3.2.2 Batterie

Le stockage d'énergie est l'un des composants clés permettant aux utilisateurs d'électricité de participer activement aux opérations du système et de bénéficier d'une variété d'avantages. Il existe dans la littérature une grande variété de modèles pour les batteries (Battery energy storage system : BESS). Les technologies de BESS existantes incluent: plomb-acide, nickel-cadmium, lithium-ion, air métallique, etc. Parmi ces technologies, la BESS lithium-ion présente beaucoup d'avantages grâce à sa petite taille et son faible poids. En même temps, il possède une densité d'énergie élevée et une efficacité de stockage proche de 100%. L'inconvénient majeur de la BESS lithium-ion est son coût élevé, ce qui limite son expansion d'utilisation.

L'état de charge (State of charge : SOC) du stockage est déterminé par la quantité d'énergie restante. Lors de la charge, le modèle de stockage se comporte comme le modèle de charge. À l'état de décharge, il se comporte comme une source de production. Le SOC de la BESS à un instant donné dépend directement de l'état de charge précédent, qui doit être connu au préalable. Le calcul de SOC de la BESS est défini par :

$$\text{SOC}_i(t+1) = \begin{cases} \text{SOC}_i(t) + \eta_{\text{ch},i} \cdot P_{\text{ch},i}(t) \cdot \Delta T / \text{NC}_{\text{bess},i} & \text{Charge} \\ \text{SOC}_i(t) + (1/\eta_{\text{disch},i} \cdot \text{NC}_{\text{bess},i}) \cdot P_{\text{disch},i}(t) \cdot \Delta T & \text{Décharge} \end{cases} \quad (3-2)$$

où NC_{bess} est la capacité nominale de la BESS. η_{ch} et η_{disch} sont les rendements de charge et de décharge de la BESS. P_{ch} et P_{disch} sont les puissances de charge et de décharge de la BESS. Si la BESS se recharge, $P_{\text{ch}} > 0$. Si la BESS se décharge, $P_{\text{disch}} < 0$. ΔT est le temps d'échantillonnage, t est l'indice de temps et i est l'indice de la BESS.

3.2.3 Générateur diesel

Les DG sont beaucoup utilisés dans les MG, notamment dans les sites isolés, grâce à leur efficacité et de leurs fiabilités élevées. Les DG ont le rôle de fournir de l'énergie de réserve et de réduire les pics de consommation. De nombreuses échelles ont été utilisées, allant de 1 kW à plusieurs dizaines de MW. Le modèle économique du DG décrit la consommation de carburant en fonction de sa puissance de sortie, ce qui en déduit en coût en \$. Il peut être modélisé par un modèle simple du premier, second et troisième ordres [4].

La puissance de sortie du DG est modélisée en utilisant les variables continues et mixtes discrètes/continues pour caractériser les modes de fonctionnement continu et OFF/ON, respectivement, comme présenté au début de ce chapitre.

3.3 Étapes nécessaires pour le dimensionnement optimal d'un MG

La combinaison de deux ou plusieurs sources d'énergie pour former un MG permet de fournir l'électricité de manière plus économique et fiable tout en satisfaisant les exigences écologiques. La préoccupation majeure dans la conception de tel système est le dimensionnement optimal afin de minimiser le coût de production d'électricité. Ainsi, le recours au réseau principal et/ou aux sources d'énergie conventionnelle doit être minimisé.

❖ Caractéristiques météorologiques

Les données météorologiques sont indispensables pour le processus d'optimisation du site d'implantation du projet. Les données de vents sont les entrées indispensables pour la stratégie d'optimisation du MG. Plus ces données sont disponibles, l'optimisation sera plus performante, car elles permettent de mieux prédire le comportement de l'ensemble du système.

❖ Profil de la demande

Le profil de charge est indispensable pour le dimensionnement et l'opération du MG. En effet, il est difficile d'obtenir les vrais profils de charge à cause de la fluctuation instantanée. La collecte du profil de charge doit être faite avec beaucoup de soin, car toute erreur peut causer le surdimensionnement ou sous-dimensionnement du MG.

❖ Configuration du système

Après avoir étudié et analysé la base de données météorologique (tel que le profil de vent) et le profil de charge, l'étape suivante consiste à la configuration du système. Cette dernière dépend de la nature des composants, par exemple si le lieu de l'étude du MG

possède un bon potentiel de vent, le MG doit être configuré avec une part maximale du système éolien.

3.4 Fonction de coût

3.4.1 Fonction de coût du DG

Le coût d'opération du DG est composé du coût de consommation de carburant et du coût de démarrage.

$$C_{dg,i}(t) = FC_i(t) + STC_i(t) \quad (3-3)$$

où FC est le coût de consommation de carburant, STC est le coût fixe du démarrage et i est l'indice du DG.

- Le coût de consommation de carburant peut être exprimé en fonction de la puissance de sortie et peut être modélisé par un polynôme quadratique. Le taux de consommation de carburant peut être exprimé comme suit [4]:

$$FC_i(t) = a_i \cdot P_{dg,i}^2(t) \cdot \Delta T + b_i \cdot P_{dg,i}(t) \cdot \Delta T + c_i \cdot \Delta T \quad (3-4)$$

où a, b et c sont les coefficients de coût du carburant. Ces paramètres varient en fonction de la dimension et du type de DG. ΔT est le pas d'échantillonnage.

- Le coût de démarrage/arrêt est défini par le coût fixe pour chaque démarrage :

$$STC_i(t) = C_{stc,i} \cdot |U_i(t) - U_i(t - 1)| \quad (3-5)$$

où C_{stc} est le coût fixe du démarrage/arrêt obtenu à l'aide des données de IEEE. U est la variable binaire représentant l'état de fonctionnement du DG. $U=1$, si le DG est en marche, $U=0$, sinon.

3.4.2 Fonction de coût de la batterie

Selon [51], le coût d'utilisation de la BESS est exprimé en fonction du coût du capital et de la puissance de charge/décharge.

$$C_{\text{bess},i}(t) = \text{PCC}_i(t) + \text{OPC}_i(t) \quad (3-6)$$

où PCC est le coût par cycle représentant le vieillissement de la BESS et OPC est le coût d'opération de la BESS.

- Le terme PCC est représenté en fonction de la puissance de charge/décharge, le coût d'investissement et la capacité de la BESS.

$$\text{PCC}_i(t) = ((P_{\text{ch},i}(t) - P_{\text{disch},i}(t)) \cdot \Delta T / 2 \cdot \text{NC}_{\text{bess},i}) \cdot \text{IC}_{\text{bess}} / (A_i \cdot (1 - \text{SOC}_{\text{min}}) + B_i) \quad (3-7)$$

où A et B sont des paramètres constants de la BESS lead-acid et IC_{bess} est le coût d'investissement de la BESS.

- Le terme OPC est associé à la puissance de charge/décharge.

$$\text{OPC}_i(t) = C_{\text{ch},i} \cdot P_{\text{ch},i}(t) \cdot \eta_{\text{ch},i} \cdot \Delta T + C_{\text{disch},i} \cdot P_{\text{disch},i}(t) \cdot \Delta T / \eta_{\text{disch},i} \quad (3-8)$$

où C_{disch} est le coût d'énergie associé à la décharge de la BESS et C_{ch} est le coût d'énergie associé à la recharge de la BESS.

3.4.3 Fonction de coût du réseau

Le coût d'échange d'électricité entre le MG et le réseau principal est exprimé par :

$$C_g(t) = C_{\text{buy}}(t) \cdot P_{\text{gbuy}}(t) \cdot \Delta T + C_{\text{sell}}(t) \cdot P_{\text{gsell}}(t) \cdot \Delta T \quad (3-9)$$

où C_{buy} et C_{sell} sont les prix d'achat et de vente d'électricité, respectivement. P_{gbuy} et P_{gsell} sont les puissances d'achat et de vente de l'électricité, respectivement. Si le MG achète de l'électricité du réseau, $P_{gbuy} > 0$. Si le MG vend de l'électricité au réseau, $P_{gsell} < 0$. Il est à noter que le MG n'est pas en mesure de vendre et d'acheter de l'électricité en même temps.

3.5 Contraintes

❖ Équilibre entre la production et la demande :

$$P_{load}(t) = \sum P_{dg,i}(t) + \sum P_{wt,i}(t) + \sum P_{bess,i}(t) + P_g(t) \quad (3-10)$$

où P_{bess} est la puissance de la BESS, avec $P_{bess,i}(t) = P_{ch,i}(t) + P_{disch,i}(t)$. P_g est la puissance du réseau, avec $P_g(t) = P_{gbuy}(t) + P_{gsell}(t)$.

❖ Contrainte liée à la plage de fonctionnement: Cette contrainte assure que la puissance de sortie de chaque composant se situe dans ses limites minimale et maximale.

$$P_{wt_min,i} \leq P_{wt,i}(t) \leq P_{wt_max,i} \quad (3-11)$$

$$P_{dg_min,i} \leq P_{dg,i}(t) \leq P_{dg_max,i} \quad (3-12)$$

$$P_{bess_min,i} \leq |P_{bess,i}(t)| \leq P_{bess_max,i} \quad (3-13)$$

où P_{wt_min} , P_{dg_min} et P_{bess_min} sont les puissances minimales du WT, du DG et de la BESS, respectivement. P_{wt_max} , P_{dg_max} et P_{bess_max} sont les puissances maximales du WT, du DG et de la BESS, respectivement.

- ❖ Contraintes des taux de montée et descente: Cette contrainte s'assure que les variations de puissance sur des périodes consécutives sont limitées. En raison des limitations de contraintes thermiques et de certaines caractéristiques mécaniques de certains composants, il n'est pas possible de permettre les variations rapides de puissance.

$$|P_{wt,i}(t) - P_{wt,i}(t - 1)| \leq \Delta P_{wt,i} \quad (3-14)$$

$$|P_{dg,i}(t) - P_{dg,i}(t - 1)| \leq \Delta P_{dg,i} \quad (3-15)$$

où ΔP_{wt} est le taux de variation de puissance du WT (kW/h) et ΔP_{dg} est le taux de variation de puissance du DG (kW/h).

- ❖ Contraintes des temps d'arrêt et marche: Si le DG est en marche, il y aura un temps minimal de fonctionnement avant de pouvoir l'arrêter. Une fois que le DG a été arrêté, il ne peut pas être redémarré immédiatement.

$$T_i^{on}(t) - MUT_i \geq 0 \quad (3-16)$$

$$T_i^{off}(t) - MDT_i \geq 0 \quad (3-17)$$

où T^{on} est la durée que le DG est resté en marche (h) et MUT est la durée minimale que le DG devrait rester en marche (h). T^{off} est la durée que le DG est en arrêt (h) et MDT est la durée minimale que le DG devrait rester en arrêt (h).

- ❖ Le SOC de la BESS devrait être maintenu entre les limites minimale et maximale afin d'éviter la dégradation rapide.

$$SOC_{min} \leq SOC_i(t) \leq SOC_{max} \quad (3-18)$$

où SOC_{min} et SOC_{max} sont les limites minimale et maximale du SOC, respectivement.

- ❖ Le MG peut échanger de l'énergie avec le réseau principal. Les puissances d'achat et de vente sont limitées par :

$$0 \leq P_{gbuy}(t) \leq P_{gbuy_max} \quad (3-19)$$

$$0 \leq P_{gsell}(t) \leq P_{gsell_max} \quad (3-20)$$

où P_{gbuy_max} et P_{gsell_max} sont les limites maximales de puissance d'achat et de vente de l'électricité, respectivement.

3.6 Commande prédictive

La commande prédictive (Model predictive control : MPC) est une technique de contrôle avancée, qui optimise un futur horizon de prévision en tenant compte des entrées et des sorties précédentes. Le principe de la MPC est illustré à la figure 3.2 et les étapes de calcul effectuées sont les suivantes :

Étape 1: Prévoir la trajectoire optimale sur l'horizon de prévision. La longueur de cet horizon peut être fixe ou variable. La trajectoire de sortie optimale est prédite en tenant compte des entrées et des sorties précédentes.

Étape 2: Calculer les signaux de contrôle sur l'horizon de prévision.

Étape 3: Appliquer le signal de commande à partir de la séquence de signaux de contrôle (seule la première valeur est appliquée au processus).

Étape 4: L'horizon est décalé par rapport à l'étape précédente.

Étape 5: Répéter le même processus à chaque pas de temps.

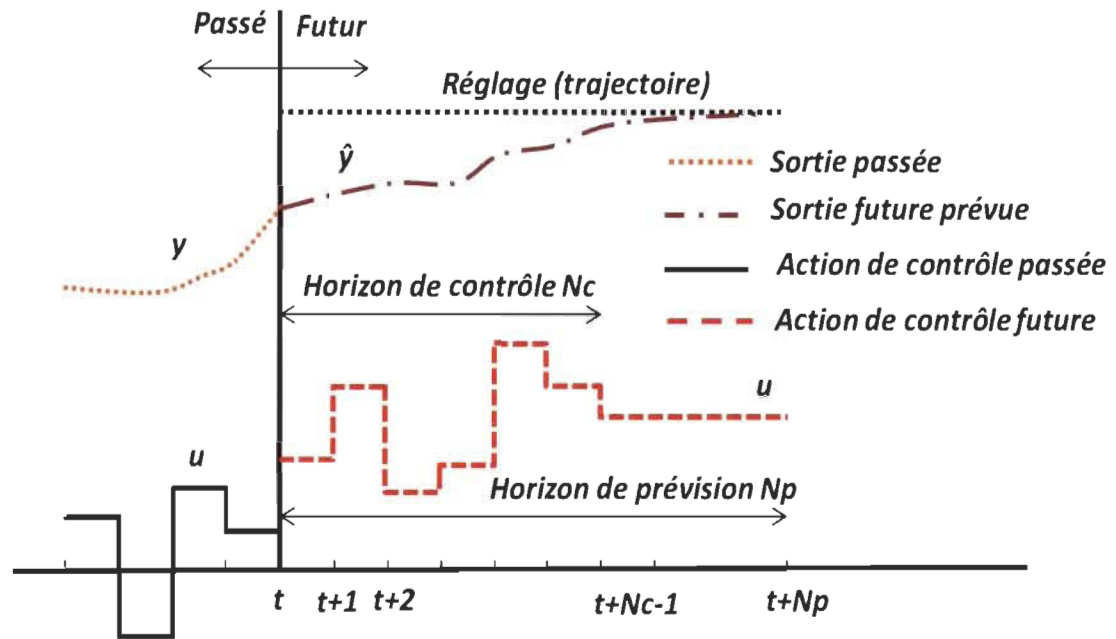


Figure 3.2 Principe de la MPC

❖ Prédiction

Plusieurs travaux ont été réalisés afin de prévoir la production et la demande pour anticiper l'aptitude d'exploitation du réseau électrique. Parmi tous les modèles de prévision, le modèle autorégressif et moyenne mobile (Autoregressive moving average : ARMA), le modèle intégré autorégressif et moyenne mobile (Autoregressive integrated moving average : ARIMA) et l'ANN sont les plus utilisés. En général, la prévision à court terme est généralement plus précise que la prévision à moyen ou à long terme.

Pour l'exploitation en temps réel du MG utilisant la MPC, les données futures sur la production et la demande doivent être prévues et mises à jour en permanence pour déterminer la répartition optimale de la puissance au sein du système. Jusqu'à présent, la prévision de ces futurs profils est uniquement effectuée sur la base des valeurs précédentes des données.

Le modèle ARMA est une technique de série chronologique simple, efficace et bien connue. L'équation du modèle ARMA est représenté par [83, 84]:

$$X(t) = \varepsilon(t) + \sum_{j=1}^p \theta_j X(t-j) + \sum_{k=1}^q \phi_k \varepsilon(t-k) \quad (3-21)$$

Le modèle ARMA est composé de deux termes, l'un est autorégressif (AR) et le second est une moyenne mobile (MA). Les données de série chronologique X sont connues comme un processus ARMA (p, q), où p est l'ordre de l'AR et q est l'ordre de la MA. De plus, θ et ϕ sont les paramètres du modèle et sont obtenus par l'utilisation de la fonction ARMAX dans MATLAB. ε est un terme d'erreur de bruit blanc qui suit une distribution gaussienne avec un moyen zéro et un écart-type σ : $\varepsilon \sim (0, \sigma)$. Les valeurs de p et q sont obtenues en utilisant le critère d'information d'Akaike. Il est à noter que les résultats de prévision peuvent également être obtenus en utilisant la fonction PREDICT dans MATLAB.

❖ Horizon de prévision variable

L'utilisation du même horizon de prévision ne présente pas d'avantages en termes de temps de calcul. À cet égard, l'horizon de prévision variable de la MPC (Adaptive horizon MPC : AH-MPC) a été proposé dans cette étude. Celui-ci est capable de mettre à jour et réduire l'horizon de prévision N_p à chaque pas de temps. L'AH-MPC incorpore l'état de fonctionnement du DG et l'intervalle de la planification. Si le DG conserve le même état de fonctionnement, N_p prendra sa valeur maximale N_M et diminuera un par un à chaque pas de temps (h); sinon, N_p gardera la valeur de N_M . N_p doit passer à N_M avant le jour suivant.

$$N_{p_t} = \begin{cases} |(U_t - U_{t-1})N_M| + |(2U_t - 1)(N_M - t + 1)| & 1 < t < 24; N_M \geq 24 \\ N_M & \text{sinon} \end{cases} \quad (3-22)$$

La figure 3.3 illustre des scénarios de l'AH-MPC avec $N_M = 24$. Les lignes orange représentent $N_p = N_M$ et les lignes noires montrent la variation de N_p . À $t = 3$ h, nous considérons deux scénarios possibles, dans lesquels N_p détient deux valeurs différentes. Le premier scénario représente le cas où le DG change l'état de fonctionnement, on obtient $N_{p3} = N_M$. Le deuxième scénario décrit le cas où le DG garde le même état de fonctionnement, on obtient $N_{p3} = N_M - 2$.




Figure 3.3 Principe de changement de l'horizon de prévision

3.7 Modèle à risque proportionnel

Le modèle à risque proportionnel (Proportional hazards model : PHM) est devenu un modèle de régression statistique important dans de nombreuses études sur la fiabilité des systèmes mécaniques ou électriques car il permet de quantifier le taux de risque [85, 86]:

$$h_i(t, Z(t)) = h_{0i}(t) \cdot \delta_i(Z(t)) = \frac{\beta_i \cdot t^{\beta_i - 1}}{\alpha_i^{\beta_i}} \cdot e^{\gamma_i \cdot Z_i(t)} \quad (3-23)$$

où $h(t)$ est le taux de risque à l'instant t . $Z(t)$ est le vecteur de covariable. $h_0(t)$ représente la fonction de risque de base qui suit une fonction de Weillbul. $\delta_i(Z(t))$ désigne

la fonction de lien qui indique l'influence de la covariable $Z(t)$ sur le taux de risque. $Z(t) = 1$, si le composant est en fonctionnement, et 0 sinon. α et β sont les paramètres de la fonction Weillbul. γ est le coefficient de la covariable et i est l'indice du composant.

La fiabilité conditionnelle R à l'instant $t+1$ est donnée par [86]:

$$R_i(t+1|t) = P_i(t_{p,i} > t+1 | t_{p,i} > t) = \exp\left(-\int_t^{t+1} h_i(x, Z_i(x))dx\right) \quad (3-24)$$

où t_p est le temps de défaillance du composant.

La probabilité de défaillance au temps $t+1$ est notée par:

$$\begin{aligned} F_i(t+1) &= 1 - R_i(t) \cdot R_i(t+1|t) = 1 - (1 - F_i(t)) \cdot R_i(t+1|t) \\ &= 1 - \exp\left(-\int_t^{t+1} h_i(x, Z_i(x))dx\right) + F_i(t) \cdot \exp\left(-\int_t^{t+1} h_i(x, Z_i(x))dx\right) \quad (3-25) \end{aligned}$$

3.8 Valeur de Shapley

Dans la théorie des jeux, la valeur de Shapley (Shapley value : SV) est une méthode de distribution équitable des gains à plusieurs joueurs travaillant en coalition. La théorie des jeux est nécessaire lorsque deux ou plusieurs joueurs sont impliqués dans une stratégie pour atteindre le gain souhaité. La méthode SV s'applique principalement dans les situations où les contributions de chaque joueur sont inégales, mais chaque joueur travaille en coopération les uns avec les autres pour obtenir le gain.

La méthode SV garantit que chaque joueur gagne autant ou plus qu'il aurait à agir de manière indépendante. La méthode SV est peut-être la méthode la plus couramment utilisée pour répartir les coûts dans les jeux à partage des coûts, car elle garantit l'existence d'un

équilibre dans n'importe quel jeu, quels que soient ses paramètres. La méthode SV s'exprime comme suit [87, 88]:

$$\phi_j(M, v) = \sum_{S \subseteq N} \frac{|S|!(|M|-|S|-1)!}{M!} [v(S \cup \{j\}) - v(S)] \quad (3-26)$$

où $\phi_j(M, v)$ est la valeur de SV du j-th joueur. $v(\cdot)$ est le bénéfice du joueur j à la coalition S. M est le nombre de joueurs. j est l'indice du joueur. S est le sous-ensemble de M pour calculer le taux contribution du j-th joueur. |S| est le nombre de joueurs en coalition. Dans notre cas, chaque MG est considéré comme un joueur dans le fonctionnement en mode coopératif.

3.9 Conclusion

Dans ce chapitre, nous avons abordé les différentes formulations du problème d'optimisation pour le MG telles que les optimisations continue, binaire et semi-continue. Nous avons décrit le fonctionnement et des formules mathématiques des composants du MG, notamment le WT, le DG et la BESS. Les formules mathématiques représentant les coûts et contraintes de fonctionnement de chaque composant sont aussi décrites. Nous avons aussi défini plusieurs méthodes et outils mathématiques afin de modéliser les différents aspects dans le fonctionnement du MG. Ces modèles seront utilisés et appliqués dans les travaux développés dans le chapitre suivant.

Chapitre 4 - Modèle d'optimisation hiérarchisé pour la planification et l'opération en temps réel du MG

Ce chapitre est consacré à la planification et l'opération en temps réel du MG sur laquelle s'appuie le modèle d'optimisation à deux niveaux. Dans un premier temps, nous présentons la procédure de la planification sous l'optimisation dite «hors ligne» qui minimise le coût d'opération d'un jour à l'avance en fonction des prévisions de la production et la demande. Ensuite, nous adressons le problème de l'opération court terme sous l'optimisation dite «temps réel». Ensuite, nous décrivons le modèle d'optimisation hiérarchisé à deux niveaux par la combinaison des optimisations hors ligne et en temps réel. La dernière partie présente les résultats d'optimisation obtenus par chaque niveau ainsi que ceux obtenus par deux niveaux.

4.1 Formulation du modèle d'optimisation hiérarchisé

4.1.1 Optimisation hors ligne pour la planification

Lorsque nous connaissons le profil de vent et de charge à l'avance, le problème de planification peut être formulé comme un problème d'optimisation hors ligne. En réalité, la connaissance préalable du futur profil de vent et de charge est très difficile et contient souvent des erreurs. Il est impossible dans ce cas d'obtenir une solution optimale, l'objectif est donc de trouver la solution qui est le plus proche possible de la solution optimale.

La fonction objectif est formulée comme une fonction unique décrivant le coût associé à tous les composants et peut être exprimée sous la forme générale comme suit:

$$\min C_{op} = \min \sum_{t=1}^T C_{wt,i}(t) + C_{dg,i}(t) + C_{bess,i}(t) + C_g(t) \quad (4-1)$$

Soumis aux contraintes (3-10) - (3-20) présentées au chapitre 3.

où C_{op} est le coût total d'opération, C_{wt} est le coût du WT, C_{dg} est le coût d'opération du DG, C_{bess} est le coût d'utilisation de la BESS, C_g est le coût d'énergie du réseau et T est l'horizon de temps. Nous supposons que le coût du WT est nul, car le vent est une source d'énergie gratuite.

- **Représentation de contrainte probabiliste**

La puissance éolienne et la charge sont des paramètres incertains. Ces derniers peuvent être dus à l'observabilité limitée des données, aux mesures bruyantes, aux implémentations et aux erreurs de prévision. Dans ce travail de recherche, nous allons proposer l'optimisation globale sous la contrainte probabiliste qui prend en compte l'erreur de prévision de la puissance éolienne. Cependant, nous formulons les équations en présence de l'erreur de prévision de la charge. Dans l'annexe A, nous présentons la formulation du problème dans le cas où l'erreur de prévision de la charge dépend de celle de la puissance éolienne. Dans cette même annexe, nous proposons la formulation en tenant compte les incertitudes associées aux erreurs moyennes de la prévision. Ainsi, les résultats de simulation de tels problèmes ont été fournis.

Nous pouvons modéliser la contrainte d'équilibre de puissance (3-10) et la contrainte de limitation de la puissance du DG (3-12) sous forme de contrainte probabiliste.

$$P_{\text{load}}(t) + \zeta_{\text{load}}(t) = \sum (P_{\text{dg},i}(t) + R_i(t)) + P_{\text{wt}}(t) + \zeta_{\text{wt}}(t) + P_{\text{bess}}(t) + P_g(t) \quad (4-2)$$

$$R_i(t) = \text{dg}_i(t) \cdot (\zeta_{\text{load}}(t) - \zeta_{\text{wt}}(t)) \quad (4-3)$$

$$P_{\text{dg_min},i} \leq P_{\text{dg},i}(t) + R_i(t) \leq P_{\text{dg_max},i} \quad (4-4)$$

$$\Pr \{P_{\text{dg},i}(t) + R_i(t) \leq P_{\text{dg_max},i}\} \geq 1 - \epsilon \quad (4-5)$$

$$\Pr \{P_{\text{dg},i}(t) + R_i(t) \geq P_{\text{dg_min},i}\} \geq 1 - \epsilon \quad (4-6)$$

Pr est la distribution de probabilité conjointe. ζ_{wt} et ζ_{load} sont les variables aléatoires représentant les erreurs de prévision du profil de puissance de WT et de charge. Nous supposons que ces deux paramètres sont indépendants. dg représente le facteur de participation de chaque DG. ϵ représente le niveau de confiance qui prend souvent une petite valeur ($\epsilon = 5\%$). i est l'indice du DG. L'équation (4-2) indique qu'un seul WT et une seule BESS ont été pris en compte dans le MG.

Remarque: Afin de simplifier le calcul, nous avons assumé que les erreurs de prévision sont uniquement compensées par les DG.

- **Résolution du problème de contrainte probabiliste**

L'optimisation robuste de distribution (Distributionally robust optimization : DRO) peut être utilisée pour approximer l'optimisation de contrainte probabiliste, et par conséquent l'optimisation robuste de distribution à contraintes aléatoires (Distributionally robust chance-constrained programming : DRCCP) a été formulée, et ne nécessite aucune distribution d'incertitude exacte. Le DRCCP permet une violation de certaines contraintes sous un intervalle de confiance spécifique, et la reformulation est toujours traitable. Le

DRCCP considère la pire distribution plutôt que le pire scénario, afin d'éviter la solution conservatrice.

1. Transformation de contrainte probabiliste

Le problème d'optimisation à contraintes probabilistes est difficile à résoudre, principalement parce que la région réalisable décrite par les contraintes (4-5) et (4-6) est en général non convexe. Néanmoins, il existe des solutions pour retrouver la convexité des modèles à contraintes probabilistes.

En particulier, ζ_{wt} et ζ_{load} sont supposées suivre une distribution gaussienne avec les moyennes connues (μ_{wt} et μ_{load}) et les matrices de covariance (Σ_{wt} et Σ_{load}), alors les contraintes probabilistes peuvent être décrites par l'équation de cône du second degré (Second order cone programming : SOCP) [89, 90].

$$\sqrt{\frac{1-\epsilon}{\epsilon}} \sqrt{dg_i^T \Sigma_{load} dg_i + dg_i^T \Sigma_{wt} dg_i} \leq P_{dg_max,i} - P_{dg,i} - dg_i \mu_{load} + dg_i \mu_{wt} \quad (4-7)$$

$$\sqrt{\frac{1-\epsilon}{\epsilon}} \sqrt{dg_i^T \Sigma_{load} dg_i + dg_i^T \Sigma_{wt} dg_i} \leq -P_{dg_min,i} + P_{dg,i} + dg_i \mu_{load} - dg_i \mu_{wt} \quad (4-8)$$

Ce théorème montre que nous pouvons recapturer la convexité du DRCCP en utilisant l'ensemble d'ambiguïtés D_{wt} et D_{load} afin de modéliser les incertitudes de ζ_{wt} et ζ_{load} . Peut-être plus intéressante, la région convexe réalisable caractérisée par le DRCCP est la représentation sous forme de SOCP. Cette dernière peut être résolue très efficacement par des méthodes d'optimisation.

2. Démonstration de la reformulation

Les deux premiers moments de ζ_{wt} peuvent être estimés par la moyenne de l'échantillon et la matrice de covariance de l'échantillon [91].

$$\mu_{wt} = \frac{1}{N} \sum_{n=1}^N \zeta_{wt} \quad (4-9)$$

$$\Sigma_{wt} = \frac{1}{N} \sum_{n=1}^N (\zeta_{wt} - \mu_{wt})(\zeta_{wt} - \mu_{wt})^T \quad (4-10)$$

Si la dimension des données N augmente, μ_{wt} et Σ_{wt} convergent vers la vraie moyenne et la vraie matrice de covariance de ζ_{wt} .

Dans le DRO, la distribution de probabilité de la variable incertaine (aléatoire) est supposée restreinte dans un ensemble d'ambiguïtés. En général, il existe de nombreuses méthodes pour établir l'ensemble d'ambiguïtés. Ici, nous construisons l'ensemble d'ambiguïtés en supposant que toutes les distributions de probabilités possibles dans l'ensemble d'ambiguïtés ont la même matrice de moyenne et de covariance. L'ensemble d'ambiguïtés est donc représenté par :

$$D_{wt} = \left\{ \Pr \in \mathcal{P}(R) : \begin{array}{l} E[\zeta_{wt}] = \mu_{wt} \\ E[(\zeta_{wt} - \mu_{wt})(\zeta_{wt} - \mu_{wt})^T] = \Sigma_{wt} \end{array} \right\} \quad (4-11)$$

où $\mathcal{P}(R)$ représente l'ensemble de toutes les distributions de probabilité sur R . idem pour la variable ζ_{load} (répéter les équations (4-9) - (4-11)).

L'approche DRCCP est représentée par:

$$\inf_{\Pr \in D} \mathbb{P}\{\mathcal{A}^T \zeta \leq B\} \geq 1 - \epsilon \quad (4 - 12)$$

Nous appliquons l'inégalité Chebyshev-Cantelli:

$$\Pr\{\zeta - \mu \geq h\} \leq \frac{\sigma^2}{\sigma^2 + h^2} \quad (4-13)$$

- À partir de l'équation (4-5), nous déduisons:

$$\Pr\{dg_i(\zeta_{load} - \zeta_{wt}) - dg_i\mu_{load} + dg_i\mu_{wt} \geq P_{dg_max,i} - P_{dg,i} - dg_i\mu_{load} + dg_i\mu_{wt}\} \leq \epsilon \quad (4-14)$$

Nous appliquons l'équation (4-12) dans (4-13):

$$\Pr\{dg_i(\zeta_{load} - \zeta_{wt}) - dg_i\mu_{load} + dg_i\mu_{wt} \geq P_{dg_max,i} - P_{dg,i} - dg_i\mu_{load} + dg_i\mu_{wt}\} \leq \frac{\sigma^2}{\sigma^2 + (P_{dg_max,i} - P_{dg,i} - dg_i\mu_{load} + dg_i\mu_{wt})^2} \quad (4-15)$$

$$\frac{\sigma^2}{\sigma^2 + (P_{dg_max,i} - P_{dg,i} - dg_i\mu_{load} + dg_i\mu_{wt})^2} \leq \epsilon \quad (4-16)$$

où $\sigma^2 = dg_i^T \Sigma_{load} dg_i + dg_i^T \Sigma_{wt} dg_i$

$$\frac{dg_i^T \Sigma_{load} dg_i + dg_i^T \Sigma_{wt} dg_i}{dg_i^T \Sigma_{load} dg_i + dg_i^T \Sigma_{wt} dg_i + (P_{dg_max,i} - P_{dg,i} - dg_i\mu_{load} + dg_i\mu_{wt})^2} \leq \epsilon \quad (4-17)$$

$$\sqrt{\frac{1-\epsilon}{\epsilon}} \sqrt{dg_i^T \Sigma_{load} dg_i + dg_i^T \Sigma_{wt} dg_i} \leq P_{dg_max,i} - P_{dg,i} - dg_i\mu_{load} + dg_i\mu_{wt} \quad (4-18)$$

L'équation (4-18) est sous forme de SOCP. Il est à noter que la notation dg_i^T indique la matrice transposée de dg_i . Ainsi, la somme de dg_i doit être égale à 1.

- À partir de l'équation (4-6), nous déduisons :

$$\Pr\{dg_i(\zeta_{load} - \zeta_{wt}) - dg_i\mu_{load} + dg_i\mu_{wt} \leq P_{dg_min,i} - P_{dg,i} - dg_i\mu_{load} + dg_i\mu_{wt}\} \leq \epsilon \quad (4-19)$$

Nous appliquons l'équation (4-12) dans (4-19) :

$$\Pr\{dg_i(\zeta_{load} - \zeta_{wt}) - dg_i\mu_{load} + dg_i\mu_{wt} \leq P_{dg_min,i} - P_{dg,i} - dg_i\mu_{load} + dg_i\mu_{wt}\} \leq \frac{\sigma^2}{\sigma^2 + (P_{dg_min,i} - P_{dg,i} - dg_i\mu_{load} + dg_i\mu_{wt})^2} \quad (4-20)$$

$$\text{où } \sigma^2 = dg_i^T \Sigma_{load} dg_i + dg_i^T \Sigma_{wt} dg_i$$

$$\frac{dg_i^T \Sigma_{load} dg_i + dg_i^T \Sigma_{wt} dg_i}{dg_i^T \Sigma_{load} dg_i + dg_i^T \Sigma_{wt} dg_i + (-P_{dg_min,i} + P_{dg,i} + dg_i\mu_{load} + dg_i\mu_{wt})^2} \leq \epsilon \quad (4-21)$$

$$\sqrt{\frac{1-\epsilon}{\epsilon}} \sqrt{dg_i^T \Sigma_{load} dg_i + dg_i^T \Sigma_{wt} dg_i} \leq -P_{dg_min,i} + P_{dg,i} + dg_i\mu_{load} - dg_i\mu_{wt} \quad (4-22)$$

L'équation (4-22) est sous forme de SOCP. Notez que les équations (4-18) et (4-22) sont obtenues sous l'hypothèse que l'erreur de prévision de la puissance éolienne est indépendante de celle de la charge. Notez que notre MG est composé d'un WT et d'un groupe de charge, Σ_{wt} et Σ_{load} pourraient être interprétées comme les simples variances σ_{wt}^2 et σ_{load}^2 , respectivement.

4.1.2 Optimisation en temps réel pour l'exploitation court terme

Dans la section précédente, nous avons traité le problème de la planification en tant que problème d'optimisation déterministe sous forme de SOCP. La solution optimale obtenue

exige une connaissance préalable du profil de vent et de charge sur un intervalle de temps donné. Nous allons, au cours de cette section, traiter le problème d'exploitation en temps réel. L'objectif est toujours de minimiser le coût d'opération.

La fonction objectif est formulée comme une fonction unique décrivant le coût associé à tous les composants et peut être exprimée comme suit:

$$\min C_{op}(t) = \min \sum C_{wt,i}(t) + C_{dg,i}(t) + C_{bess,i}(t) + C_g(t) \quad (4-23)$$

Soumis aux contraintes (3-10) - (3-20) présentées au chapitre 3.

4.1.3 Modèle d'optimisation hiérarchisé

Ce modèle d'optimisation caractérise un modèle de prise de décision hiérarchique à deux niveaux pour un problème de planification et d'exploitation en temps réel du MG. Chaque niveau contrôle indépendamment ses variables de décision. La figure 4.1 illustre un modèle d'optimisation hiérarchisé de la planification jusqu'à la commande du MG.

Le niveau inférieur reçoit des informations et les points de consigne sur l'horizon de planification obtenu par le niveau supérieur afin d'évaluer le coût d'opération. L'optimisation au niveau inférieur est basée sur la commande prédictive à l'horizon de prévision variable (AH-MPC) qui re-détermine les points de fonctionnement des composants tout en minimisant le coût de fonctionnement en fonction des paramètres reçus. Dans la stratégie choisie, l'optimisation dans la phase de la planification est faite sur l'horizon de 24 h à l'avance. Notez que pour profiter d'une meilleure précision des prévisions à moyen ou court terme, la planification peut se répéter plusieurs fois dans la journée sur un horizon glissant.

L'AH-MPC met à jour le plan de production à chaque pas de temps, en utilisant les données de prévision à court terme. L'AH-MPC est une version modifiée de la version standard de la MPC. En utilisant cette approche, l'horizon de prévision est réduit à chaque pas de temps, ce qui entraîne une réduction du temps de calcul. Cependant, cela pourrait affecter la capacité de l'algorithme à atteindre la solution optimale.

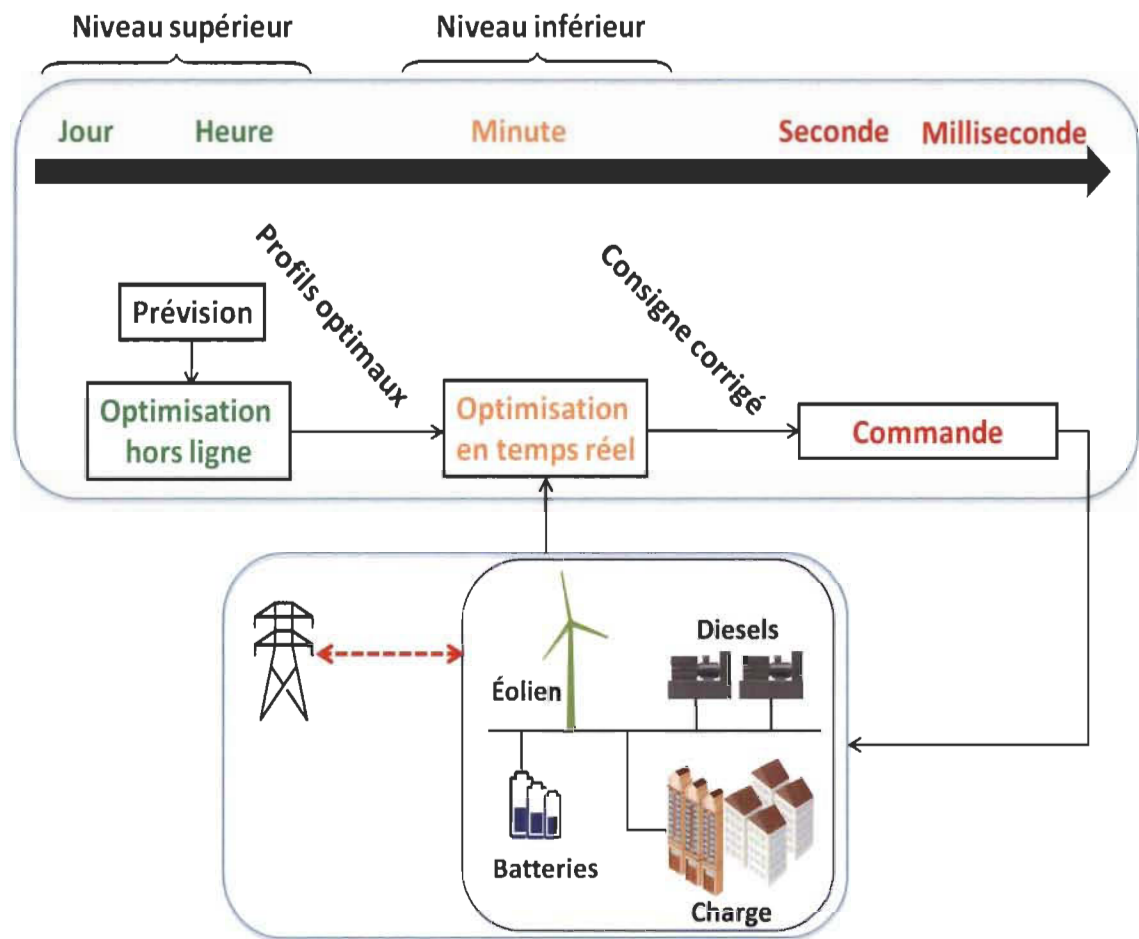


Figure 4.1 Modèle d'optimisation hiérarchisé du MG

4.2 Simulation

4.2.1 Configuration de la simulation

Dans cette section, nous évaluons le modèle proposé et comparons les résultats obtenus par l'optimisation en temps réel avec ceux obtenus à partir de la planification hors ligne. L'algorithme PSO est appliqué pour résoudre le problème d'optimisation. La simulation est effectuée pour un horizon temporel de 24 h avec un pas de temps de 1 h (pour l'optimisation hors ligne) et de 30 min (pour l'optimisation en temps réel). L'algorithme proposé est implémenté dans MATLAB 2017 installé sur un PC avec un processeur Intel Core i5 2.5 GHz et 8 Go de RAM.

Dans cette étude, le MG est composé d'un WT, deux DG et une BESS. Seule la charge critique a été prise en compte. Le MG est connecté au réseau principal. Le WT a une capacité de 2 MW qui fonctionne avec des vitesses de vent de 3 à 25 m/s. La capacité du DG est de 1.7 MW. La capacité nominale de la BESS est de 2 MWh.

Les annexes B et D représentent les paramètres de simulation des algorithmes PSO et HBPSO. Dans l'annexe C, les valeurs de μ_{wt} et σ_{wt} ont été données. Les paramètres de simulation pour chaque composant ont été donnés dans l'annexe E. Le coût d'achat de la BESS est basé sur le prix réel du marché, et les coefficients de coût du combustible sont sélectionnés afin de reproduire le prix réel de l'électricité par kWh.

Les coûts d'opération dérivés par les algorithmes PSO et HBPSO ont été comparés. Le dimensionnement de la BESS est l'un des critères importants à étudier pour montrer son influence sur le coût d'opération. Le profil de charge est extrait des données d'Hydro-Québec et est illustré sur la figure 4.2. Ce profil représente la puissance de charge

résidentielle du village Kuujjuarapik pendant d'une journée durant l'été. La puissance de charge maximale est d'environ 1.7 MW. La vitesse du vent est sélectionnée pendant la période défavorable. La puissance du WT est représentée sur la figure 4.3. Les données de vitesse du vent et les caractéristiques du WT ont été extraites de Simeb et Vesta, respectivement. Le prix de l'électricité du réseau est indiqué sur la figure 4.4. Le prix d'achat de l'électricité est imité au prix d'électricité de la province de l'Ontario, Canada. Le prix de vente de l'électricité est supposé être proportionnel au prix d'achat.




Figure 4.2 Profil de charge




Figure 4.3 Puissance du WT




Figure 4.4 Prix d'échange d'électricité du réseau

4.2.2 Résultats d'optimisation à un seul niveau

- **Optimisation hors ligne pour la planification**


L'optimisation hors ligne a été menée afin d'examiner les performances et servir en tant que consigne de l'optimisation en temps réel. Le coût obtenu par cette stratégie peut être considéré comme le seuil inférieur du coût total d'opération du MG.

Dans ce cas, la prévision du profil de charge et de la puissance éolienne a été effectuée pour l'horizon de 24 h, ce qui fait $N_p = 24$ et aucune mise à jour d'informations n'a été effectuée. Ainsi, les valeurs de contrôle obtenues par l'optimisation hors ligne sont appliquées pour tout l'horizon. En effet, la moindre erreur de prévision conduit à un fonctionnement optimal de chaque composant tout en garantissant le coût minimal d'opération.


Le fonctionnement optimal des DG en utilisant l'optimisation hors ligne a été présenté dans la figure 4.5 (a)-(b). On peut constater que les DG fournissent les puissances assez similaires (~ 400 - 700 kW) dans la plupart du temps, en utilisant le PSO et le HBPSO. Les

deux DG fonctionnent en continu avec leur puissance optimale obtenue par le PSO. En utilisant le HBPSO, le premier et le deuxième DG sont passés à l'état OFF entre 8-9 h et 16-17 h, respectivement. Lorsque les DG sont passés à l'état OFF, l'algorithme rassure que les SOC n'atteignent pas leur limite inférieure afin de garantir la continuité de l'énergie électrique. La puissance optimale du réseau est représentée sur la figure 4.5 (c). On remarque que cette puissance est négative durant 0-15 h, ce qui indique que le MG fournit de l'énergie au réseau durant cette période. À partir de 16 h, le MG sollicite la puissance du réseau à cause de l'augmentation de la charge.


La puissance optimale de la BESS et les variations de SOC sont représentées sur la figure 4.5 (d)-(e). En utilisant le PSO et le HBPSO, la BESS se recharge pendant que l'énergie éolienne est élevée, ce qui conduit à l'augmentation du SOC.




(a) Puissance du DG No. 1




(b) Puissance du DG No. 2



(c) Puissance du réseau



(d) Puissance de la BESS



(e) État de charge de la BESS

Figure 4.5 Résultat obtenu par l'optimisation hors ligne

- **Optimisation en temps réel pour l'exploitation court terme**


Dans l'optimisation en temps réel, la prévision et la mise à jour des informations sont exécutées à chaque pas d'échantillonnage. Le calcul du processus d'optimisation associé à l'horizon de prévision a été effectué à chaque pas d'échantillonnage, mais seule la première valeur des signaux de contrôle est appliquée au système.

Le choix de l'horizon de prévision est un critère important pour le processus d'optimisation en temps réel. Si l'horizon de prévision est long, l'algorithme fournit un meilleur ensemble de solutions. Néanmoins, cela nécessite un long temps d'exécution. Dans ce cas, nous avons supposé que N_p varie de 1 à 24. À cet égard, le temps d'exécution est réduit tout en conservant une bonne solution.


La figure 4.6 montre le fonctionnement optimal des DG, le réseau et la BESS à l'aide des algorithmes PSO et HBPSO. On observe que le premier DG génère une puissance assez identique en utilisant le PSO et le HBPSO. Le deuxième DG est passé à l'état OFF entre

3h30min-4h en utilisant le HBPSO, car la charge est faible pendant cette période. Nous pouvons également voir que malgré la grande variation du profil de charge et de la puissance éolienne, les démarrages/arrêts des DG n'ont pas augmenté. Dans ce cas, le MG fournit plus d'énergie au réseau principal en comparant au cas précédent.


Le plan optimal de la charge et de la décharge de la BESS sont gérés en fonction de la puissance éolienne et de la charge. À cette fin, la BESS est chargée lorsque la puissance éolienne est élevée et ensuite déchargée lorsque la puissance éolienne est faible et pendant la période de pointe. La BESS agit comme une réserve d'énergie éolienne. Le SOC augmente pendant l'intervalle de 7-10 h et 15-19 h. Le SOC est faible à partir de 20 h en raison de la faible puissance éolienne, ce qui indique que la BESS n'est pas capable de supporter la charge plus élevée.




(a) Puissance du DG No. 1




(b) Puissance du DG No. 2



(c) Puissance du réseau



(d) Puissance de la BESS



(e) État de charge de la BESS

Figure 4.6 Résultat obtenu par l'optimisation en temps réel

• Discussions

Les coûts d'opération obtenus par différentes stratégies d'optimisation sont fournis aux tableaux 4-1. Le coût minimal est atteint par l'optimisation en temps réel. Dans la première observation, nous voyons que les optimisations hors ligne basées sur le PSO et le HBPSO fournissent des solutions très identiques. Dans la deuxième observation, nous constatons que les coûts d'opération obtenus par l'optimisation en temps réel sont inférieurs à ceux obtenus hors ligne.

Tableau 4-1 Coût d'opération obtenu par le PSO

	Coût (\$)	
	PSO	HBPSO
Hors ligne	1 803	1 827
Temps réel	1 731	1 748

Dans le tableau 4-2, une comparaison des coûts d'opération est fournie lorsque l'approche DRCCP (hors ligne) est appliquée pour résoudre le problème de planification du MG sous différents niveaux de confiance ϵ . L'impact du niveau de confiance ϵ sur le coût de fonctionnement du MG a également été étudié. Lorsque ϵ augmente, l'intervalle de confiance $1 - \epsilon$ diminue, ce qui implique la diminution du coût de fonctionnement.


Tableau 4-2 Coût d'opération sous différents niveaux de confiance (obtenu par le PSO)

ϵ	Coût (\$)
0.5 %	2 065
1 %	1 983
3 %	1 876
5 %	1 803
7 %	1 788
10 %	1 759
100 %	1 724


4.2.3 Résultats d'optimisation hiérarchisée à deux niveaux (PSO)

Les puissances optimales des DG, la BESS et le réseau basé sur l'optimisation à deux niveaux sont illustrés à la figure 4.7. Les puissances des DG de l'approche à deux niveaux sont légèrement fluctuées par rapport au profil optimal obtenu par l'optimisation hors ligne au niveau supérieur. Malgré tout, la plage de fonctionnement des DG reste appropriée, car les DG ne fonctionnent pas avec leur puissance maximale.


La fluctuation de la puissance de la BESS et du réseau est plus importante que le cas précédent. Cependant, le SOC est maintenu dans une plage appropriée dans la plupart du temps et sa valeur finale est maintenue élevée.




(a) Puissance du DG No. 1




(b) Puissance du DG No. 2



(c) Puissance du réseau



(d) Puissance de la BESS



(e) État de charge de la BESS

Figure 4.7 Résultat obtenu par l'optimisation à deux niveaux (PSO)

- **Comparaison entre l'approche hors ligne déterministe et DRCCP**

L'approche déterministe assume une connaissance parfaite des profils de vent et de charge d'un jour à l'avance tandis que l'approche DRCCP suppose l'erreur de prévision. Le modèle DRCCP réduit la conservabilité du modèle déterministe. Il fournit également des planifications robustes pour tous les scénarios incertains afin de garantir la solution réalisable pour l'optimisation au niveau inférieur.

Tableau 4-3 Coût d'opération obtenu par l'approche déterministe

	Coût (\$)
Niveau supérieur	1 779
Optimisation à deux niveaux	1 721

Tableau 4-4 Coût d'opération obtenu par l'approche DRCCP

	Coût (\$)
Niveau supérieur	1 803
Optimisation à deux niveaux	1 713

Les tableaux 4-3 et 4-4 comparent l'efficacité de la solution de l'approche déterministe et l'approche DRCCP dans la résolution du problème d'optimisation hiérarchisé. L'approche déterministe fournit un coût de 1 779 \$ au niveau supérieur, tandis que l'approche DRCCP fournit un coût de 1 803 \$. Dans ce cas, on peut conclure que la solution obtenue par l'approche déterministe est autant efficace que celle obtenue par l'approche DRCCP, à condition qu'on obtienne une meilleure précision de prévision. Cependant, on peut observer que les coûts d'opération obtenus par l'optimisation à deux niveaux (pour les deux approches) sont très similaires.

- **Dimensionnement de la batterie**

La figure 4.8 montre l'influence de la capacité de la BESS sur le coût total d'opération. On peut observer que le coût d'opération diminue lorsqu'on augmente la capacité de la BESS. À ce stade, nous devons noter que le coût d'achat et d'installation augmentera en fonction de la capacité de la BESS. Le point qui doit être souligné ici est que le coût d'opération n'est pas optimal lorsque la capacité de la BESS diminue à 1 MWh en raison de la violation de la contrainte de SOC. Cette dernière implique un coût supplémentaire (coût de pénalité) à ajouter au coût total d'opération.




Figure 4.8 Impact du dimensionnement de la BESS sur le coût total d'opération

4.3 Conclusion

Dans ce chapitre, nous avons présenté, dans un premier temps, la planification hors ligne d'un MG connecté au réseau en présence de l'erreur de prévision de la production d'énergie éolienne et par conséquent nous avons proposé une nouvelle formulation basée sur le DRO, appelé le DRCCP. Nous avons également abordé l'exploitation du MG en temps réel avec des horizons de prévision variable. Nous avons mis en évidence l'efficacité des algorithmes PSO et HBPSO pour résoudre ces problèmes.

Par la suite, le modèle d'optimisation hiérarchisé à deux niveaux a été présenté. Les résultats de la simulation ont montré que le modèle d'optimisation hiérarchisé à deux niveaux réduit la quantité d'énergie importée du réseau et la consommation du carburant et donc assure le coût minimal d'opération. En outre, nous avons observé que le dimensionnement de la BESS a une influence sur le coût total d'opération du MG. Dans le prochain chapitre, nous allons ajouter à ce modèle hiérarchisé l'approche robuste pour la

gestion stochastique basée sur les scénarios afin de mieux capter l'incertitude du profil de vent.

Chapitre 5 - Modèle d'optimisation hiérarchisé pour la planification et l'opération en temps réel du MG intégrant l'approche robuste-stochastique

Ce chapitre présente la formulation du modèle d'optimisation hiérarchisé à deux niveaux pour la planification et l'opération en temps réel du MG. Le chapitre commence par la présentation du modèle de l'incertitude de la production d'énergie éolienne. Ensuite, le chapitre développe l'approche de résolution de problème d'optimisation robuste-stochastique basé sur les scénarios. Il détaille la résolution du problème tout en proposant le nouveau concept de l'algorithme PSO. Ensuite, la formulation du modèle d'optimisation hiérarchisé et les résultats obtenus seront discutés.

5.1 Modélisation de l'incertitude basée sur les scénarios

Dans cette étude, l'incertitude provenant du profil de charge est faible et peut être négligée et seule l'incertitude du profil de vent a été prise en compte.

Nous proposons une approche robuste-stochastique basée sur des scénarios afin de gérer l'incertitude du profil de vent. Dans un premier temps, la prévision de la vitesse du vent est obtenue par le modèle ARMA. Ensuite, une simulation Monte-Carlo (MC) est implémentée afin de générer un grand nombre de scénarios de la vitesse du vent. Cette stratégie a été présentée dans [92, 93].

❖ Génération et réduction des scénarios

Notez que le modèle ARMA a été présenté dans le chapitre 3. À cette fin, nous supposons que l'erreur de prévision de la puissance éolienne \mathcal{E}_{wt} suit la distribution gaussienne avec une moyenne zéro et un écart-type σ : $\mathcal{E}_{wt} \sim (0, \sigma)$.

Afin d'obtenir une meilleure modélisation de l'incertitude, un grand nombre de scénarios ont été générés. Cependant, cela nécessite un temps de calcul élevé pour résoudre le problème. De ce fait, la technique de réduction des scénarios a été utilisée afin de diminuer le nombre total de scénarios en omettant les scénarios répétitifs ou à faible probabilité. La méthode de réduction des scénarios peut conserver une bonne approximation du comportement incertain du système. Dans ce travail, la méthode Sélection directe (Forward selection : FS) a été utilisée comme technique de réduction de scénario.

❖ Méthode FS

Dans cette méthode, la sélection du scénario est répétée jusqu'à ce qu'un nombre prescrit de scénarios préservés soit sélectionné. Pour expliquer les principes de cette méthode, considérons un ensemble de scénarios (Ω_s) contenant (N_s) scénarios, chacun avec la probabilité d'occurrence (Π_s), que la distance Kantorovich [94] entre deux scénarios (s , s) est indiquée par les (DTs). Les scénarios sont omis jusqu'à ce que le nombre souhaité de scénarios réduits (k) soit atteint. La procédure de la méthode FS est décrite sur la figure 5.1.

Étape 0: Créer un ensemble de scénarios vide. $k = 0$

Étape 1: Calculer la distance Kantorovich entre chaque scenario DT_s

Étape 2: Choisir le scénario ω_k avec la moindre distance et supprimer ce scénario. $k = k+1$

Étape 3: Mettre à jour l'ensemble de scénarios $\Omega_s = N_s - k \setminus \omega_k$

Étape 4: Répéter l'étape 1 à 3 jusqu'à ce que k atteigne le nombre de scénarios souhaité

Figure 5.1 Procédure de la méthode FS

La méthode MC a été utilisée pour générer 100 scénarios et la méthode FS a été utilisée pour les réduire à 20 scénarios. Les scénarios générés et réduits sont illustrés dans les figures 5.2 et 5.3. Dans la figure 5.2, la courbe en noire représente le profil de vent obtenu par le modèle ARMA ($\mathcal{E}_{wt} \sim (0, 0)$) et les courbes en vertes représentent les scénarios générés. Notez que les scénarios générés sont obtenus à partir du profil obtenu par la prévision.




Figure 5.2 Scénarios de la vitesse du vent (100 scénarios)




Figure 5.3 Scénarios (réduit) de la vitesse du vent (20 scénarios)

5.2 Formulation d'optimisation robuste sous l'impact de l'incertitude du profil de vent

Tout d'abord, nous précisons que le même modèle du MG, vu au chapitre précédent, a été utilisé tout au long de cette étude. De cette manière, l'incertitude peut agir sur le fonctionnement des DG, la BESS et le réseau. De manière plus simple, nous avons supposé que l'incertitude agit particulièrement sur les DG. Donc, il existe un cas de fonctionnement du DG qui provoque le moindre d'impact sur le coût total d'opération, c'est-à-dire qu'avec ce cas, le coût total d'opération est le plus bas. Le coût total d'opération avec le moindre impact est formulé comme suit :

$$F_L(X) = \min f(X, U) \quad (5-1)$$

où X représente le coût d'opération des DG et U représente le coût d'opération de la BESS et du réseau.

De même, il existe un cas qui cause le pire impact sur le coût total d'opération, cela correspond donc au coût total d'opération le plus élevé.

$$F_H(X) = \max f(X,U) \quad (5-2)$$

Par conséquent, pour un certain fonctionnement des DG, le coût total d'opération $f(X,U) \in [F_L(X), F_H(X)]$.

Pour chaque scénario de la vitesse du vent, l'approche d'optimisation robuste prend en compte le cas qui provoque $F_H(X)$, c'est-à-dire avec le pire impact sur le coût total d'opération. Donc, le problème d'optimisation avec la prise en compte du pire impact de l'incertitude (la vitesse du vent) sur le coût total d'opération est représenté comme suit :

$$\min F_H(X) = \min\text{-}\max f(X,U) \quad (5-3)$$

Le problème min-max est un problème d'optimisation robuste à deux couches. Chaque valeur de X est liée à U , ce qui entraîne le coût total d'opération le plus élevé. Les valeurs de X (les variables d'optimisation de la couche interne) ont un impact direct sur les valeurs de U (les variables d'optimisation de la couche externe).

5.3 Modèle d'optimisation hiérarchisé

L'objectif du modèle d'optimisation hiérarchisé est de trouver les décisions optimales dans le cadre de la planification et l'opération en temps réel. La procédure de calcul est représentée sur la figure 5.4.

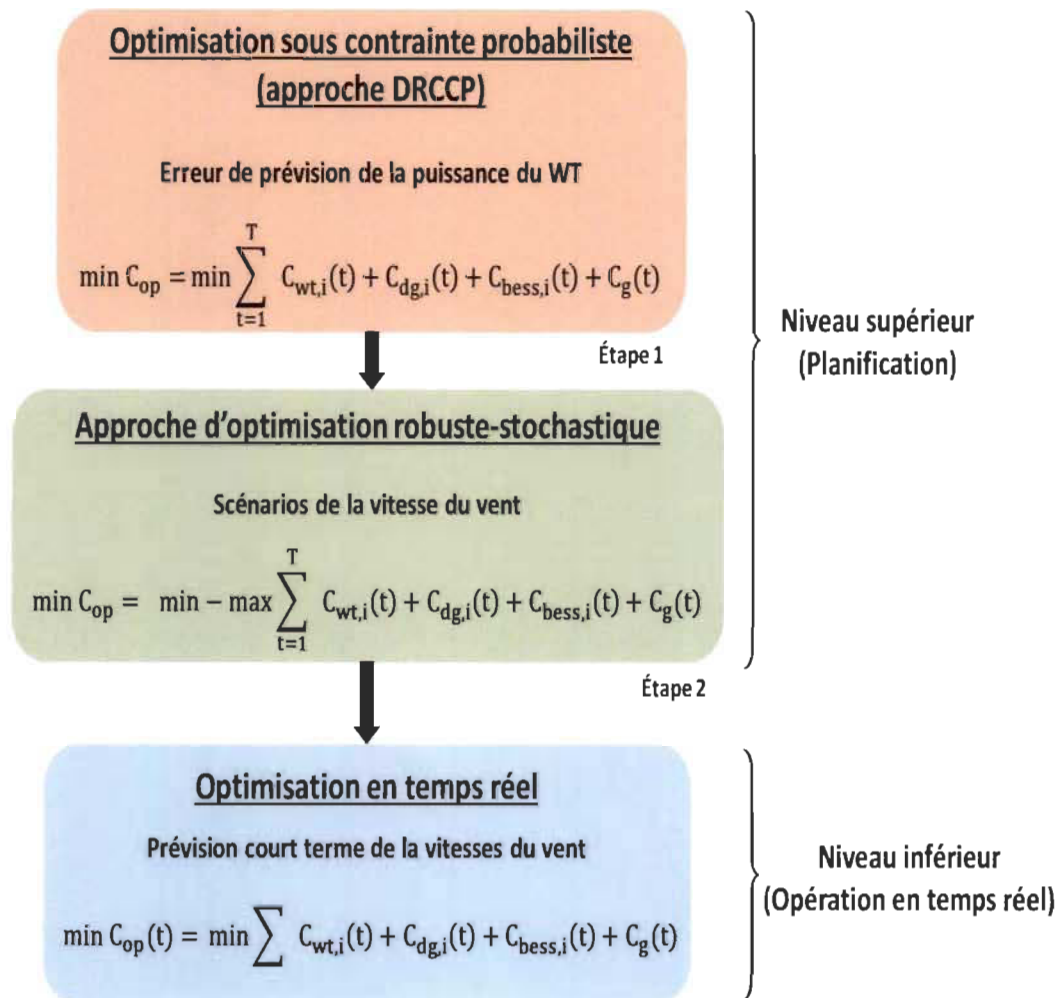


Figure 5.4 Procédure de calcul du modèle d'optimisation hiérarchisé

L'optimisation au niveau supérieur se réalise en deux étapes. La première étape définit le profil optimal des puissances de chaque composant sous l'erreur de prévision de la puissance du WT. La formulation du problème à cette étape est représentée sous contrainte probabiliste (réalisée dans le chapitre précédent). Dans la deuxième étape, les profils optimaux des puissances de chaque composant sous différents scénarios de la vitesse du vent ont été définis.

Ensuite, nous tentons de chercher l'erreur minimale entre la solution obtenue par l'approche DRCCP et robuste-stochastique. L'équation pour le calcul de l'erreur est définie par :

$$x = \frac{|S_{rso} - S_{drc}|}{S_{drc}} \quad (5-4)$$

où S_{rso} est le coût obtenu à partir de chaque scénario et S_{drc} est le coût obtenu à partir de l'approche DRCCP.

Enfin, nous choisissons le profil optimal qui correspond au scénario avec la moindre erreur en tant que consigne pour l'optimisation au niveau inférieur.

Les décisions prises au niveau supérieur correspondent à la planification à partir des scénarios du profil de vent. Les décisions de recours au niveau inférieur re-optimise les consignes en temps réel pour l'ajustement de puissance de sortie de tous les composants.

❖ Fonction objectif du niveau supérieur

L'optimisation à ce niveau vise à minimiser le coût total d'opération du MG selon l'erreur de prévision de la puissance du WT et des scénarios de la vitesse de vent. Ceux-ci conduisent à l'optimisation sous deux étapes.

(1) La première étape utilise l'approche DRCCP vue au chapitre 4. La fonction objectif de cette étape est représentée par :

$$\min C_{op} = \min \sum_{t=1}^T C_{wt,i}(t) + C_{dg,i}(t) + C_{bess,i}(t) + C_g(t) \quad (5-5)$$

Soumis aux contraintes (3-10) - (3-20) présentées au chapitre 3 ainsi que les contraintes probabilistes (4-5) et (4-6) présentées au chapitre 4.

(2) La deuxième étape consiste à l'approche robuste-stochastique basée sur les scénarios de la vitesse du vent. La fonction objectif de la deuxième étape a été extraite à partir de l'équation (5-3) et est représentée comme suit :

$$\min C_{op} = \min - \max \sum_{t=1}^T C_{wt,i}(t) + C_{dg,i}(t) + C_{bess,i}(t) + C_g(t) \quad (5-6)$$

Soumis aux contraintes (3-10) à (3-20) présentées au chapitre 3.

❖ Fonction objectif du niveau inférieur

L'objectif d'optimisation à ce niveau est de minimiser le coût total d'opération en temps réel tout en satisfaisant les contraintes (3-10) - (3-20) présentées au chapitre 3. La fonction objectif peut être représentée comme suit :

$$\min C_{op}(t) = \min \sum C_{wt,i}(t) + C_{dg,i}(t) + C_{bess,i}(t) + C_g(t) \quad (5-7)$$

5.4 Approche d'optimisation robuste

L'optimisation robuste a été récemment introduite pour incorporer l'incertitude dans les modèles de programmation mathématique. L'idée clé est de couvrir les solutions contre les pires réalisations des paramètres incertains. Dans le cadre de cette thèse, nous proposons la formulation de l'approche robuste visant à minimiser le coût total d'opération pour chaque scénario de la vitesse du vent. L'approche proposée a été développée via la coévolution de l'algorithme PSO.

❖ Solution et méthodologie

L'algorithme IP-GA a été proposé dans [95] pour rechercher la planification optimale de la consommation d'énergie des appareils électriques. Dans l'article [96], l'algorithme IP-EA a été proposé afin d'optimiser le coût d'électricité des appareils domestiques. Ici, nous adoptons l'algorithme PSO-PSO pour résoudre le problème d'optimisation robuste-stochastique du MG. L'algorithme IP-GA est un algorithme composé du GA interne et du GA externe tandis que l'algorithme IP-EA est composé du GA interne et du PSO externe. L'algorithme PSO-PSO est un algorithme composé du PSO interne et du PSO externe. Les algorithmes IP-EA, IP-GA et PSO-PSO sont quasiment identiques, sauf que le PSO-PSO est plus efficace en termes de rapidité du calcul et qualité de la solution.

L'organigramme du PSO-PSO pour résoudre le problème de la planification du MG est illustré à la figure 5.5. L'algorithme PSO externe vise à rechercher le fonctionnement optimal de la BESS et du réseau. L'algorithme PSO interne vise à rechercher le fonctionnement des DG avec le pire impact sur le coût total d'opération. Plus précisément, pour la planification des différents composants du MG, le pire cas est obtenu via le PSO interne. Ensuite, nous pouvons obtenir le coût total d'opération avec le pire cas du fonctionnement des DG sous l'incertitude.

Il est à noter que les algorithmes IP-EA, IP-GA et PSO-PSO ne peuvent pas garantir l'optimalité globale dans tous les cas. Cependant, l'efficacité de l'algorithme PSO-PSO a été suffisamment vérifiée dans cette étude.

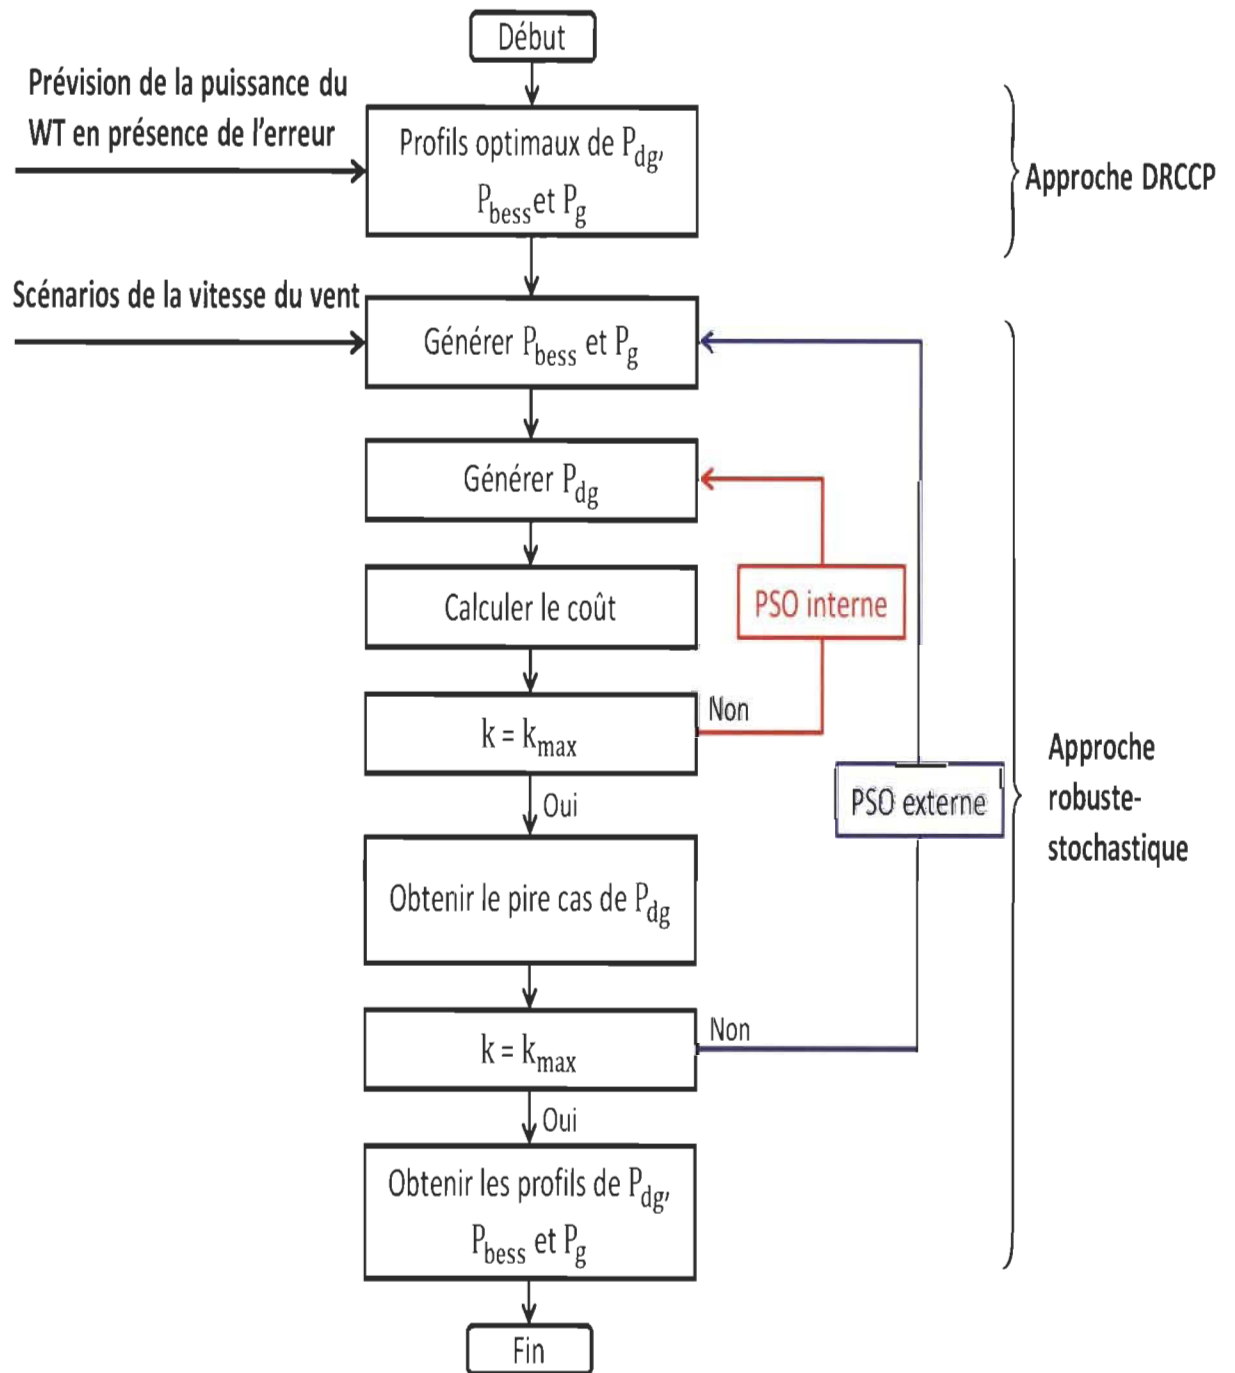


Figure 5.5 Diagramme de l'algorithme PSO-PSO

5.5 Résultats d'optimisation

Dans cette section, nous évaluons l'approche robuste-stochastique proposée et comparons les résultats obtenus (hors ligne) avec ceux de l'approche hiérarchisée à deux niveaux (en temps réel). La simulation a été effectuée pour un horizon de 24 h avec un pas de temps de 1 h (hors ligne) et de 30 min (en temps réel). Le même modèle du MG que le chapitre précédent a été implémenté dans ce chapitre.

Il est à noter que l'approche robuste-stochastique est associée à l'approche DRCCP. Afin de simplifier le calcul, nous utilisons le même profil de charge que celui du chapitre 4, comme illustré sur la figure 5.6. La puissance totale produite par le cinquième scénario de la vitesse du vent est représentée sur la figure 5.7.




Figure 5.6 Profil de charge






Figure 5.7 Puissance du WT (associée au cinquième scénario de la vitesse du vent)


Sur la figure 5.8, nous avons présenté le profil optimal obtenu par l'optimisation robuste-stochastique. Celui-ci correspond au cinquième scénario de la vitesse du vent avec la moindre erreur de coût par rapport à l'approche DRCCP. Nous pouvons voir que les DG fournissent des puissances assez constantes malgré la grande variation de la charge et l'énergie éolienne. Cependant, la puissance de la BESS et le réseau présentent plus de fluctuations.




(a) Puissance du DG No.1




(b) Puissance du DG No.2



(c) Puissance du réseau




(d) Puissance de la BESS




(e) État de charge de la BESS

Figure 5.8 Résultat obtenu au niveau supérieur par le cinquième scénario de la vitesse du vent (approche robuste-stochastique)


Sur la figure 5.9, nous avons présenté les profils optimaux obtenus par l'optimisation à deux niveaux. Les profils de puissance sont différents à ceux obtenus au niveau supérieur (approche DRCCP et robuste-stochastique). Les puissances des DG sont plus fluctuantes par rapport au cas précédent et le MG exporte plus de puissance au réseau que d'en importer.




(a) Puissance du DG No.1




(b) Puissance du DG No.2



(c) Puissance du réseau



(d) Puissance de la BESS



(e) État de charge de la BESS

Figure 5.9 Résultat obtenu par l'optimisation à deux niveaux

❖ Coût obtenu par l'approche d'optimisation robuste-stochastique

Le tableau 5-1 fournit les coûts d'opération générés par 10 scénarios de la vitesse du vent. On peut voir que le coût d'opération dans le pire scénario a augmenté de 29% par rapport à l'approche DRCCP seule, donc 2 332 \$ contre 1 803 \$.

Tableau 5-1 Coût d'opération obtenu par l'approche robuste-stochastique (20 scénarios)

	Coût (\$)		
	Meilleur	Moyen	Pire
Approche robuste-stochastique	1 769	2 028	2 332

❖ Coût obtenu par l'optimisation à deux niveaux

Comme indiqué au début de ce chapitre, l'optimisation hiérarchisée à deux niveaux relie la planification (au niveau supérieur) à l'opération en temps réel (au niveau inférieur).

L'optimisation à court terme en temps réel ajuste les résultats optimaux de la planification avec des prévisions plus précises, et détermine le coût d'opération plus précis, comme indiqué dans le tableau 5-2. Le coût obtenu par l'optimisation à deux niveaux est même moins élevé que celui obtenu par le meilleur scénario de la vitesse du vent, donc 1 713 \$ contre 1 769 \$.

Tableau 5-2 Coût d'opération obtenu par l'optimisation à deux niveaux

	Coût (\$)
Optimisation à deux niveaux	1 713

❖ Convergence de l'algorithme PSO-PSO

Afin de démontrer l'efficacité de l'algorithme, nous devons garantir que l'algorithme converge vers la valeur optimale après toutes les itérations. Les caractéristiques de convergence de la couche interne et externe du PSO-PSO sont représentées sur la figure 5.10. Les couches interne et externe du PSO-PSO ont la capacité de converger vers les valeurs optimales. Cependant, la couche interne a une vitesse de convergence plus élevée par rapport à la couche externe. Cette différence peut s'expliquer par le fait que les variables de la couche externe ont été influencées par celle de la couche interne.




Figure 5.10 Convergence de l'algorithme PSO-PSO

5.6 Conclusion

Ce chapitre 5 est consacré au modèle hiérarchisé pour la planification et l'opération en temps réel du MG. Nous avons avant tout incorporé le modèle de planification étudié dans le chapitre précédent. Ensuite, nous nous sommes intéressés à la formulation du problème d'optimisation stochastique basée sur les scénarios afin d'obtenir une solution robuste dans la phase de la planification. Ainsi, nous nous sommes focalisés sur la conception de la méthode de résolution d'une telle formulation, à savoir, la méthode de coévolution du PSO.

Après avoir obtenu le résultat sous chaque scénario du profil de vent, la sélection du profil optimal a été présentée afin d'obtenir la consigne pour l'opération en temps réel. Le modèle proposé permet de mieux capter l'incertitude liée au profil de vent afin d'éviter la solution conservatrice dans la phase de planification. Ce modèle peut aussi aider à mieux planifier les ressources disponibles afin de réduire leurs coûts d'opération et exploiter le MG en temps réel en toute conformité. Le prochain chapitre se consacre sur le modèle de

gestion hiérarchisée et distribuée des MG couplés en présence de la maintenance préventive. Ainsi, le partage équitable des coûts d'opération a été attribué à chaque MG.

Chapitre 6 - Modèle d'optimisation distribué et hiérarchisé pour la planification et l'opération en temps réel des MG considérant la maintenance préventive

Ce chapitre présente le modèle distribué et hiérarchisé pour la gestion de l'énergie dans les MG en considérant la maintenance préventive. Le chapitre commence par la présentation du modèle de gestion distribuée. Ensuite, le chapitre présente le modèle d'optimisation à deux niveaux pour la planification et l'opération en temps réel. Il détaille également les équations mathématiques qui caractérisent le modèle de maintenance du composant. Ainsi, le concept d'attribution équitable des coûts d'opération sera introduit. Le chapitre fournit une analyse complète du modèle distribué et hiérarchisé appliqué aux MG en tenant compte de la maintenance préventive. Ainsi, ce chapitre compare les résultats obtenus par le fonctionnement en mode interactif et indépendant.

6.1 Modèle de gestion distribué

Dans la littérature, il existe principalement deux approches pour la gestion de l'énergie dans les MG. La première consiste à l'approche centralisée qui est basée sur le contrôleur central. Ce dernier reçoit des informations de chacune des composants et est responsable de les contrôler. La deuxième approche pour la gestion de l'énergie dans les MG consiste donc à l'architecture de contrôle distribué. Dans cette approche, chaque composant est équipé d'un contrôleur individuel (local).

Tout au long de ce chapitre, nous allons appliquer l'approche distribuée. Chaque MG est donc équipé d'un contrôleur local permettant de déterminer l'échange d'énergie entre les MG. La structure des MG est représentée sur la figure 6.1. Chaque MG se compose d'un WT, deux DG et une BESS. Ainsi, il est capable d'échanger l'énergie avec le réseau de distribution.

6.1.1 Mode sans échange d'énergie entre les MG

Étant donné que ces MG peuvent fonctionner sans interaction entre eux, ce cas est nommé le mode de fonctionnement indépendant. La fonction objectif est représentée par :

$$\min C_{op} = \min \sum_{t=1}^T C_{op_mg,1}(t) + C_{op_mg,2}(t) + C_{op_mg,3}(t) \quad (6-1)$$

Soumis aux contraintes (3-10) à (3-20) présentées au chapitre 3. Ainsi, les contraintes probabilistes (4-5) et (4-6) présentées au chapitre 4 et la contrainte (6-12) sont prises en compte.

Les équations détaillées de la fonction de coût de chaque MG peuvent être décrites comme suit:

$$C_{op_mg,i}(t) = \sum C_{wt,i}(t) + C_{dg,i}(t) + C_{bess,i}(t) + C_g(t) \quad (6-2)$$

où $C_{op_mg,i}$ est le coût total d'opération du MG No. i ($i = 1, 2, 3$). C_{wt} est le coût lié à l'éolienne du MG No. i . C_{dg} est le coût d'opération du DG du MG No. i . C_{bess} est le coût lié au fonctionnement de la BESS du MG No. i . C_g est le coût d'échange d'énergie entre le MG No. i et le réseau principal. Les fonctions de coût associées au WT, aux DG, à la BESS et au réseau électrique sont identiques à celles utilisées dans les chapitres précédents.

6.1.2 Mode d'échange d'énergie entre les MG

Les MG sont capables d'échanger l'énergie entre eux de manière séquentielle, ce mode de fonctionnement s'appelle le fonctionnement coopératif. La structure d'échange d'énergie entre les MG est présentée sur la figure 6.1. Supposons que la puissance installée et la puissance de charge de chaque MG sont classées par l'ordre décroissant (MG No. 1 > MG No. 2 > MG No. 3), les informations ont donc été transférées du MG No. 1 au MG No. 2 et du MG No. 2 au MG No. 3. La même fonction objectif de l'expression (6-1) a été appliquée. Cependant, les coûts d'échange d'énergie entre les MG ont été ajoutés à l'équation (6-2).

Donc, nous avons obtenu :

$$C_{op_mg,1}(t) = \sum C_{wt,i}(t) + C_{dg,i}(t) + C_{bess,i}(t) + C_g(t) + C_{mg,1 \rightarrow 2}(t) \quad (6-3)$$

$$C_{op_mg,2}(t) = \sum C_{wt,i}(t) + C_{dg,i}(t) + C_{bess,i}(t) + C_g(t) + C_{mg,2 \rightarrow 1}(t) + C_{mg,2 \rightarrow 3}(t) \quad (6-4)$$

$$C_{op_mg,3}(t) = \sum C_{wt,i}(t) + C_{dg,i}(t) + C_{bess,i}(t) + C_g(t) + C_{mg,3 \rightarrow 2}(t) \quad (6-5)$$

où $C_{mg,1 \rightarrow 2}$ représente le coût d'échange d'énergie du MG No. 1 vers le MG No. 2. Ce coût est calculé à partir de l'équation de coût d'échange d'énergie entre le MG et le réseau, sauf que le tarif d'échange d'énergie entre les MG est supposé égal à 90 % du prix d'électricité du réseau. Idem pour $C_{mg,2 \rightarrow 1}$, $C_{mg,2 \rightarrow 3}$ et $C_{mg,3 \rightarrow 2}$.

Les contraintes suivantes sont indispensables afin d'introduire les restrictions d'échange de puissance entre les différents MG:

$$P_{mg,1 \rightarrow 2}(t) + P_{mg,2 \rightarrow 1}(t) = 0 \quad (6-6)$$

$$P_{mg,2 \rightarrow 3}(t) + P_{mg,3 \rightarrow 2}(t) = 0 \quad (6-7)$$

où $P_{mg,1 \rightarrow 2}$ et $P_{mg,2 \rightarrow 1}$ sont les flux de puissance du MG No. 1 vers le MG No. 2 et du MG No. 2 vers le MG No. 1, respectivement.

Si le MG No. 1 fournit la puissance au MG No. 2, nous avons $P_{mg,1 \rightarrow 2} < 0$ et $P_{mg,2 \rightarrow 1} > 0$. Idem pour la contrainte (6-7).

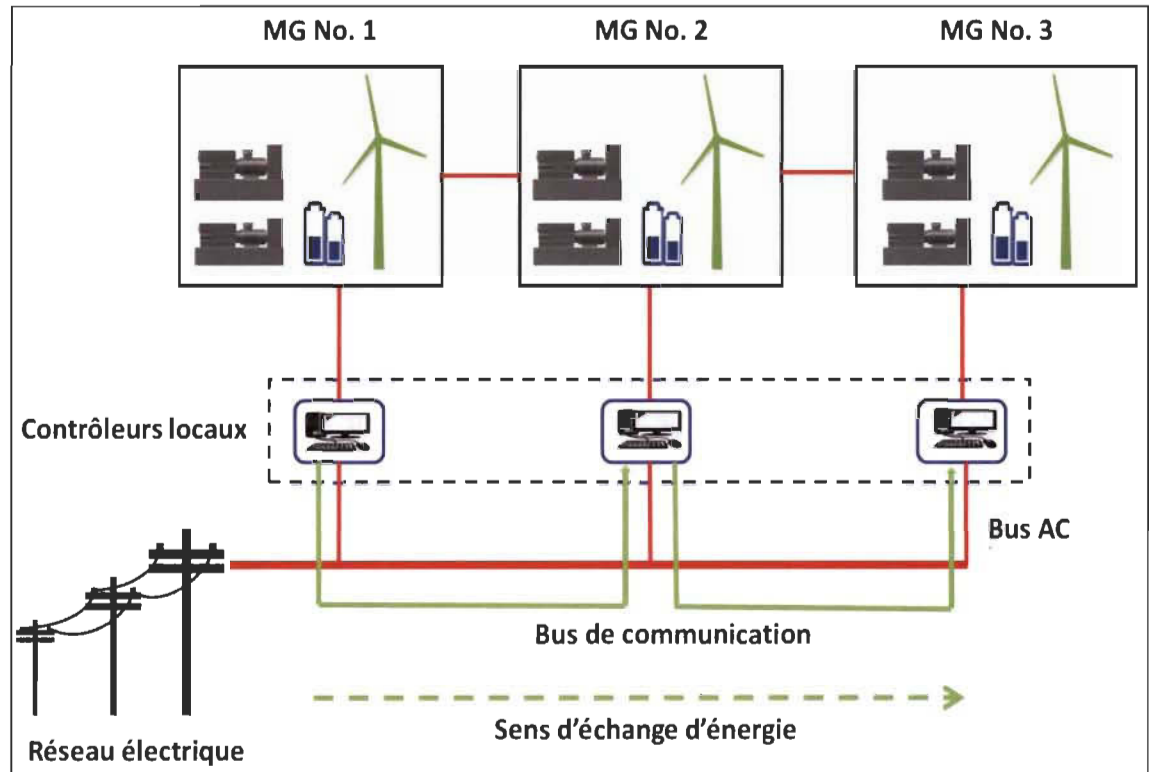


Figure 6.1 Structure des MG avec l'échange d'énergie entre eux (Mode séquentielle)

6.2 Modèle de gestion hiérarchisé

Nous utilisons la même approche d'optimisation à deux niveaux présentée au chapitre 4 en intégrant la maintenance préventive des DG.

6.2.1 Conception du niveau supérieur

Dans la première étape, la maintenance préventive des DG a été définie. Ensuite, la puissance optimale de chaque composant a été déterminée en utilisant la prévision du profil de charge et de la puissance éolienne.

- **Planification de la maintenance**

Nous appliquons le modèle à risque proportionnel (PHM) afin de définir le taux de panne du DG. Le PHM est décrit par :

$$h_i(t, Z(t)) = h_{0i}(t) \cdot \delta_i(Z(t)) = \frac{\beta_i \cdot t^{\beta_i - 1}}{\alpha_i^{\beta_i}} \cdot e^{\gamma_i \cdot Z_i(t)} \quad (6-8)$$

La fiabilité conditionnelle est représentée par :

$$R_i(t + 1|t) = P_i(t_{p,i} > t + 1 | t_{p,i} > t) = \exp\left(-\int_t^{t+1} h_i(x, Z_i(x)) dx\right) \quad (6-9)$$

La probabilité de défaillance est indiquée par :

$$\begin{aligned} F_i(t + 1) &= 1 - R_i(t) \cdot R_i(t + 1|t) = 1 - (1 - F_i(t)) \cdot R_i(t + 1|t) \\ &= 1 - \exp\left(-\int_t^{t+1} h_i(x, Z_i(x)) dx\right) + F_i(t) \cdot \exp\left(-\int_t^{t+1} h_i(x, Z_i(x)) dx\right) \end{aligned} \quad (6-10)$$

La maintenance de chaque DG s'est produite lorsque la valeur de F est supérieure au nombre aléatoire r. Par la suite, la méthode MC est appliquée afin d'estimer la durée de maintenance de chaque DG. La procédure est décrite comme suit :

- Générer aléatoirement un nombre r compris entre 0 et 1.
- Interpréter r comme une probabilité.

- Retourner la plus petite valeur de t si $F_i(t) \geq r$. Ensuite, le plan de maintenance est activé ($u=1$).

- Appliquer la méthode MC pour estimer la durée de la maintenance $t_{out,i}$. La durée de maintenance est limitée entre 1-10 h.

- **Optimisation hors ligne**

La même fonction objectif de l'expression (6-1) a été utilisée. Dans cette étude, le choix du mode de fonctionnement devrait être effectué (mode indépendant ou coopératif). Ce choix dépend du coût total d'opération obtenu par l'ensemble des MG.

$$\min C_{op} = \min \sum_{t=1}^T C_{op_mg,1}(t) + C_{op_mg,2}(t) + C_{op_mg,3}(t) \quad (6-11)$$

Soumis aux contraintes (3-10) - (3-20) présentées au chapitre 3. Ainsi, les contraintes probabilistes (4-5) et (4-6) présentées au chapitre 4 et les contraintes (6-6), (6-7) et (6-12) sont prises en compte.

- **Contrainte probabiliste associée à la durée de la maintenance**

Cette contrainte assure que la durée estimée pour la maintenance de chaque DG ne dépasse pas le temps maximal autorisé.

$$\Pr\{u_i t_{out,i} + u_i \zeta_{out,i} \leq T_{max,i}\} \geq 1 - \epsilon \quad (6-12)$$

où t_{out} est la durée estimée pour la maintenance. u représente le vecteur binaire qui représente le statut de la maintenance du DG. Si $u = 1$, cela signifie que la maintenance est en cours (si $u = 0$, le cas contraire). ζ_{out} est la variable aléatoire représentant l'erreur de la

durée estimée pour la maintenance. T_{\max} est le temps maximal autorisé pour la maintenance ($T_{\max} = 10$ h). ϵ représente le niveau de confiance ($\epsilon = 5\%$).

En particulier, ζ_{out} est supposée suivre une distribution gaussienne avec une moyenne connue μ_{out} et une matrice de covariance Σ_{out} , alors la contrainte probabiliste est équivalente au SOCP:

$$\sqrt{\frac{1-\epsilon}{\epsilon}} \sqrt{u_i^T \Sigma_{out,i} u_i} \leq T_{\max,i} - u_i t_{out,i} - u_i \mu_{out,i} \quad (6-13)$$

- Démonstration de la reformulation

Les deux premiers moments de ζ_{out} peuvent être estimés par la moyenne de l'échantillon et la matrice de covariance de l'échantillon.

$$\mu_{out,i} = \frac{1}{N} \sum_{n=1}^N \zeta_{out,i} \quad (6-14)$$

$$\Sigma_{out,i} = \frac{1}{N} \sum_{n=1}^N (\zeta_{out,i} - \mu_{out,i})(\zeta_{out,i} - \mu_{out,i})^T \quad (6-15)$$

L'ensemble d'ambiguïtés est représenté par :

$$D_{out,i} = \left\{ \Pr \in \mathcal{P}(\mathcal{R}) : \begin{array}{l} E[\zeta_{out,i}] = \mu_{out,i} \\ E[(\zeta_{out,i} - \mu_{out,i})(\zeta_{out,i} - \mu_{out,i})^T] = \Sigma_{out,i} \end{array} \right\} \quad (6-16)$$

Nous appliquons l'inégalité Chebyshev-Cantelli :

$$\Pr\{\zeta - \mu \geq h\} \leq \frac{\sigma^2}{\sigma^2 + h^2} \quad (6-17)$$

À partir de l'équation (6-12), nous déduisons :

$$\Pr\{u_i t_{out,i} + u_i \zeta_{out,i} \geq T_{max,i}\} \leq \epsilon \quad (6-18)$$

$$\Pr\{u_i t_{out,i} + u_i \zeta_{out,i} - u_i \mu_{out,i} \geq T_{max,i} - u_i \mu_{out,i}\} \leq \epsilon \quad (6-19)$$

$$\Pr\{u_i \zeta_{out,i} - u_i \mu_{out,i} \geq T_{max,i} - u_i t_{out,i} - u_i \mu_{out,i}\} \leq \epsilon \quad (6-20)$$

Nous appliquons l'équation (6-17) dans (6-20) :

$$\Pr\{u_i \zeta_{out,i} - u_i \mu_{out,i} \geq T_{max,i} - u_i t_{out,i} - u_i \mu_{out,i}\} \leq \frac{\sigma^2}{\sigma^2 + (T_{max,i} - u_i t_{out,i} - u_i \mu_{out,i})^2} \quad (6-21)$$

$$\frac{\sigma^2}{\sigma^2 + h^2} \leq \epsilon \quad (6-22)$$

$$\frac{\sigma_i^2}{\sigma_i^2 + (T_{max,i} - u_i t_{out,i} - u_i \mu_{out,i})^2} \leq \epsilon \quad (6-23)$$

où $\sigma_i^2 = u_i^T \Sigma_{out,i} u_i$

$$\frac{u_i^T \Sigma_{out,i} u_i}{u_i^T \Sigma_{out,i} u_i + (T_{max,i} - u_i t_{out,i} - u_i \mu_{out,i})^2} \leq \epsilon \quad (6-24)$$

$$\frac{u_i^T \Sigma_{out,i} u_i}{\epsilon} \leq u_i^T \Sigma_{out,i} u_i + (T_{max,i} - u_i t_{out,i} - u_i \mu_{out,i})^2 \quad (6-25)$$

$$\frac{1-\epsilon}{\epsilon} u_i^T \Sigma_{out,i} u_i \leq (T_{max,i} - u_i t_{out,i} - u_i \mu_{out,i})^2 \quad (6-26)$$

$$\sqrt{\frac{1-\epsilon}{\epsilon}} \sqrt{u_i^T \Sigma_{out,i} u_i} \leq T_{max,i} - u_i t_{out,i} - u_i \mu_{out,i} \quad (6-27)$$

L'équation (6-29) est représentée sous forme de SOCP. La notation u_i^T représente la matrice transposée de u_i . Σ_{out} pourrait être interprétée comme la simple variance σ_{out}^2 .

6.2.2 Conception du niveau inférieur

En raison de l'incertitude de la puissance éolienne, le résultat obtenu au niveau supérieur peut dévier par rapport à celui obtenu au niveau inférieur. Pour réduire l'écart, nous ré-optimisons le plan de production en utilisant les données de prévision de N_p horizon à l'avance. Enfin, le partage équitable des coûts d'opération a été attribué pour chaque MG.

- **Optimisation en temps réel**

Le niveau inférieur minimise le coût de fonctionnement en temps réel, en ajustant les références de puissance obtenues au niveau supérieur.

$$\min C_{op}(t) = \min \sum C_{op_mg,1}(t) + C_{op_mg,2}(t) + C_{op_mg,3}(t) \quad (6-28)$$

Soumis aux contraintes (3-10) - (3-20) présentées au chapitre 3 ainsi que les contraintes (6-6) et (6-7).

- **Répartition équitable des coûts**

Afin de déterminer le coût d'opération de chaque MG de manière équitable, nous appliquons la méthode Shapley (SV) qui s'exprime comme suit :

$$\phi_j(N, v) = \sum_{S \subseteq N \setminus \{j\}} \frac{|S|!(|N|-|S|-1)!}{N!} [v(S \cup \{j\}) - v(S)] \quad (6-29)$$

Chaque MG est considéré comme un joueur. La méthode SV calcule le coût d'opération pour chaque coalition des MG afin de trouver le partage équitable des coûts d'opération pour chaque MG.

Le modèle de gestion distribué et hiérarchisé est illustré sur la figure 6.2. Dans notre modèle, nous supposons que la décision de choix de mode d'opération est prise par le gestionnaire du réseau. Les détails de la procédure de calcul de l'approche proposée sont présentés comme suit :

- a. La maintenance préventive des DG est définie.
- b. Le pas de temps de 1 h des données de prévision de la vitesse du vent et de la charge, ainsi que le prix d'échange de l'énergie sont insérés au niveau supérieur. De plus, l'estimation de la durée de maintenance a été effectuée.
- c. L'optimisation est résolue sur l'horizon de 24 h en tenant compte de la maintenance préventive. Ensuite, la planification optimale est obtenue.
- d. La planification optimale a été insérée au niveau inférieur, en tenant compte de la décision du mode de fonctionnement (mode indépendant ou coopératif) des MG. Rappelons que les profils optimaux des puissances échangées entre les MG restent inchangés pendant l'optimisation en temps réel.
- e. Le pas de temps de 30 min des données de prévision de la vitesse du vent et de la charge, et le prix du marché de l'énergie sont insérés au niveau inférieur.
- f. L'optimisation est résolue sur l'horizon de prévision.
- g. Appliquer la première valeur de contrôle. L'horizon de prévision avance d'un pas en avant.
- h. La valeur de SOC a été mise à jour et utilisée pour le calcul du pas de temps suivant.
- i. Répéter les étapes (e) - (h).
- j. Calculer la répartition équitable des coûts d'opération.

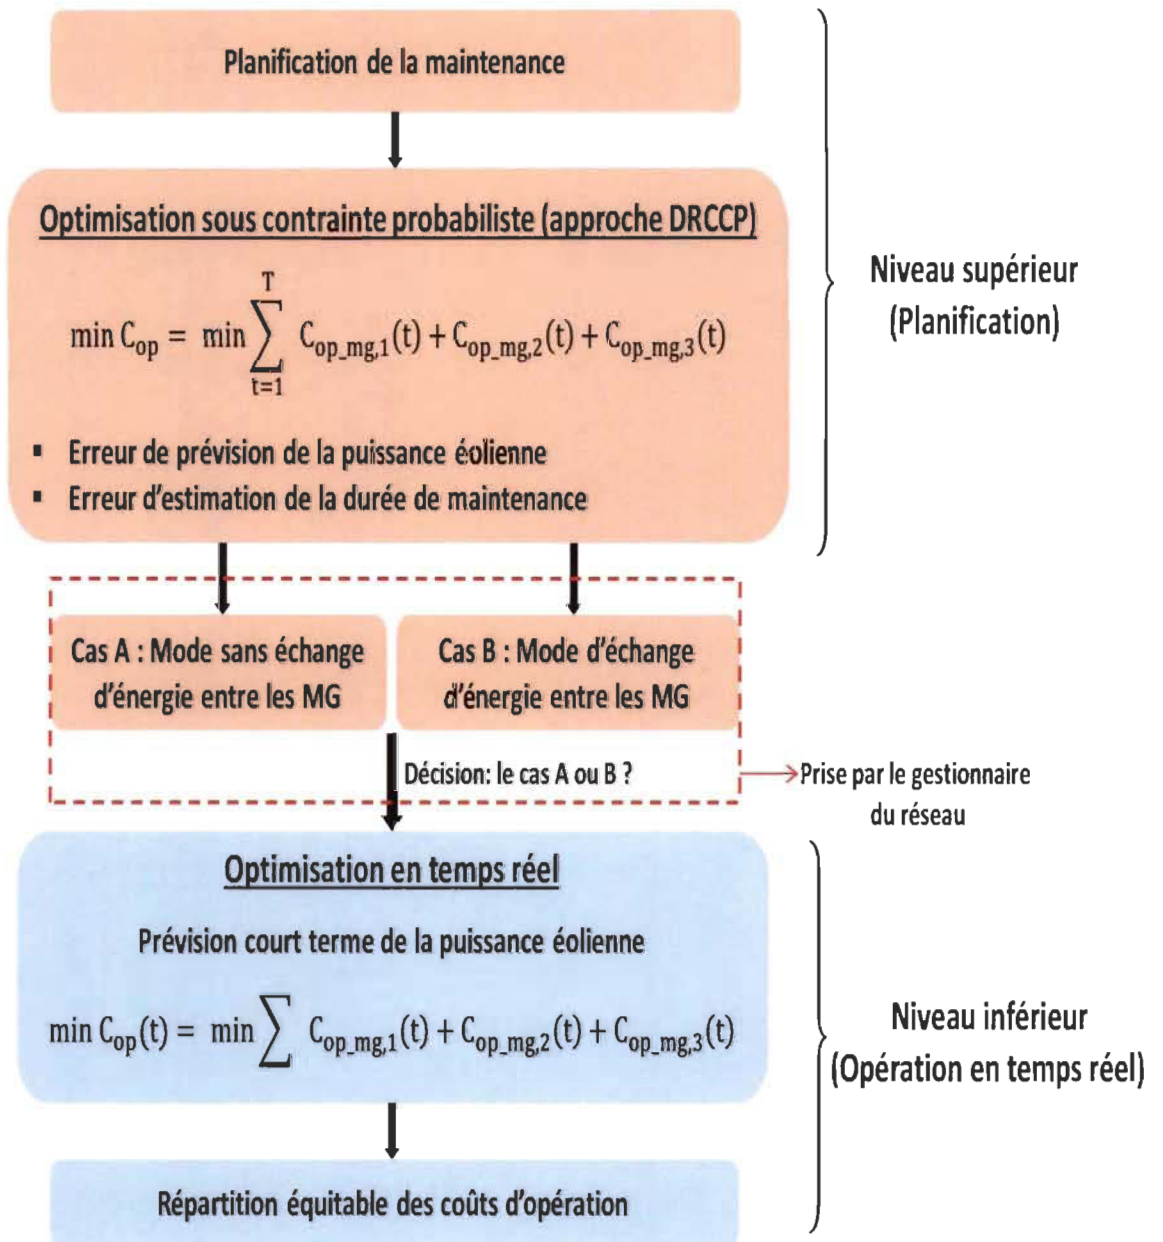


Figure 6.2 Procédure de calcul du modèle d'optimisation distribué et hiérarchisé des MG

6.3 Simulation

6.3.1 Configuration de la simulation

Comme mentionné au début du chapitre, chaque MG se compose d'un WT, deux DGs et une BESS et est capable d'échanger l'énergie avec le réseau de distribution. Le WT de chaque MG a une capacité de 2 MW, qui fonctionne avec une vitesse du vent comprise entre 4-25 m/s. Les trois MG ont une puissance maximale de charge de 3.5 MW, 2.2 MW et 1.7 MW, respectivement. Les deux DG installés dans le premier MG ont une puissance nominale de 2 MW et 1.5 MW. Les deux DG installés dans le deuxième MG ont une puissance nominale de 1.2 MW et 1 MW. Les deux DG installés dans le troisième MG ont une puissance nominale de 1 MW et 0.7 MW. La BESS installée dans le premier MG a une capacité de 3 MWh tandis que la BESS dans les deux autres MG a une capacité de 2 MWh.

Le prix d'électricité du réseau est indiqué sur la figure 6.3. Le tarif d'échange d'énergie entre les MG est supposé égal à 90 % du prix d'électricité du réseau. Les profils de charge sont représentés sur la figure 6.4. Les puissances de WT sont indiquées sur la figure 6.5.




Figure 6.3 Prix d'échange d'électricité du réseau




Figure 6.4 Profil de charge




Figure 6.5 Puissance du WT

L'optimisation au niveau supérieur est réalisée pour un horizon temporel de 24 h avec un pas de temps de 1 h. L'optimisation au niveau inférieur est réalisée pour un horizon temporel de 24 h avec un pas de temps de 30 min. Ces deux niveaux d'optimisation ont été résolus par l'algorithme PSO. L'approche proposée et l'algorithme PSO sont implémentés dans Matlab 2017 installé sur un PC avec un processeur Intel Core i5, 2.5 GHz et 8 Go de RAM.

Afin de montrer si le modèle proposé peut permettre aux MG de fonctionner efficacement, les cas de simulation suivants seront examinés: 1) comparer le coût total d'opération obtenu par l'approche à deux niveaux avec celui obtenu au niveau supérieur; 2) analyser le coût total d'opération lorsque les MG sont exploités en mode indépendant et coopératif; 3) démontrer si l'approche proposée est capable de réaliser une opération économique dans le cadre de la maintenance préventive; 4) analyser les avantages d'un système composé de plusieurs MG et calculer la répartition équitable de coût d'opération.

Les paramètres des techniques d'optimisation sont indiqués dans l'annexe F. Les caractéristiques de chaque composant, y compris les contraintes opérationnelles et les paramètres de coût, sont donnés en annexe G. Les paramètres de défaillance des DG sont donnés dans la même annexe. Ces paramètres sont considérés comme l'état de vieillissement des DG à 2 000 h de fonctionnement. Dans l'annexe H, les valeurs de μ_{out} et σ_{out} ont été fournies.

6.3.2 Résultat de la simulation

- **Avantage du modèle d'optimisation à deux niveaux**

Le tableau 6-1 compare le coût total d'opération de l'approche proposée sous un et deux niveaux d'optimisation. L'approche à deux niveaux contribue à une réduction de coût par rapport au cas où seule l'optimisation du niveau supérieur est appliquée. L'approche à deux niveaux fournit le coût total d'opération de 10 091 \$, soit environ 8 % de moins par rapport à celui obtenu au niveau supérieur. Nous pouvons également observer qu'avec le mode coopératif, le coût total d'opération est moins élevé.

Tableau 6-1 Coût total d'opération des MG

	Coût obtenu par le mode indépendant (\$)	Coût obtenu par le mode coopératif (\$)
Niveau supérieur	12 179	10 964
Optimisation à deux niveaux	11 205	10 091

Les puissances des DG, des BESS, du réseau principal ainsi que les puissances échangées entre les MG obtenus par l'optimisation à deux niveaux sont illustrées aux figures 6.6, 6.7 et 6.8. Il apparaît à la figure 6.6 (b) que le deuxième DG situé au premier MG est en maintenance de 6 à 12 h. La maintenance du deuxième DG est adéquate, car la puissance du WT est élevée tandis que la charge est faible pendant cette période. Nous pouvons constater également que le premier MG a sollicité beaucoup d'énergie du deuxième MG et du réseau principal. Ceci est dû au fait que la puissance du WT n'est pas suffisante pour satisfaire la charge. Nous pouvons également observer que notre algorithme impose les DG à fonctionner dans la plupart du temps, à faible puissance.

Les puissances des BESS ont légèrement dévié, ce qui provoque la déviation sur les puissances des DG. Cependant, les SOC sont toujours maintenus dans une plage appropriée afin de garantir la continuité de l'alimentation. Une attention particulière pourrait porter sur la BESS du premier MG, car on peut constater que le SOC est maintenu élevé avant la maintenance du DG afin de contribuer au fonctionnement du MG pendant que le DG est en interruption. Ceci peut être expliqué par le fait que notre modèle est capable d'anticiper le fonctionnement optimal du système tout en rassurant la continuité de la production.

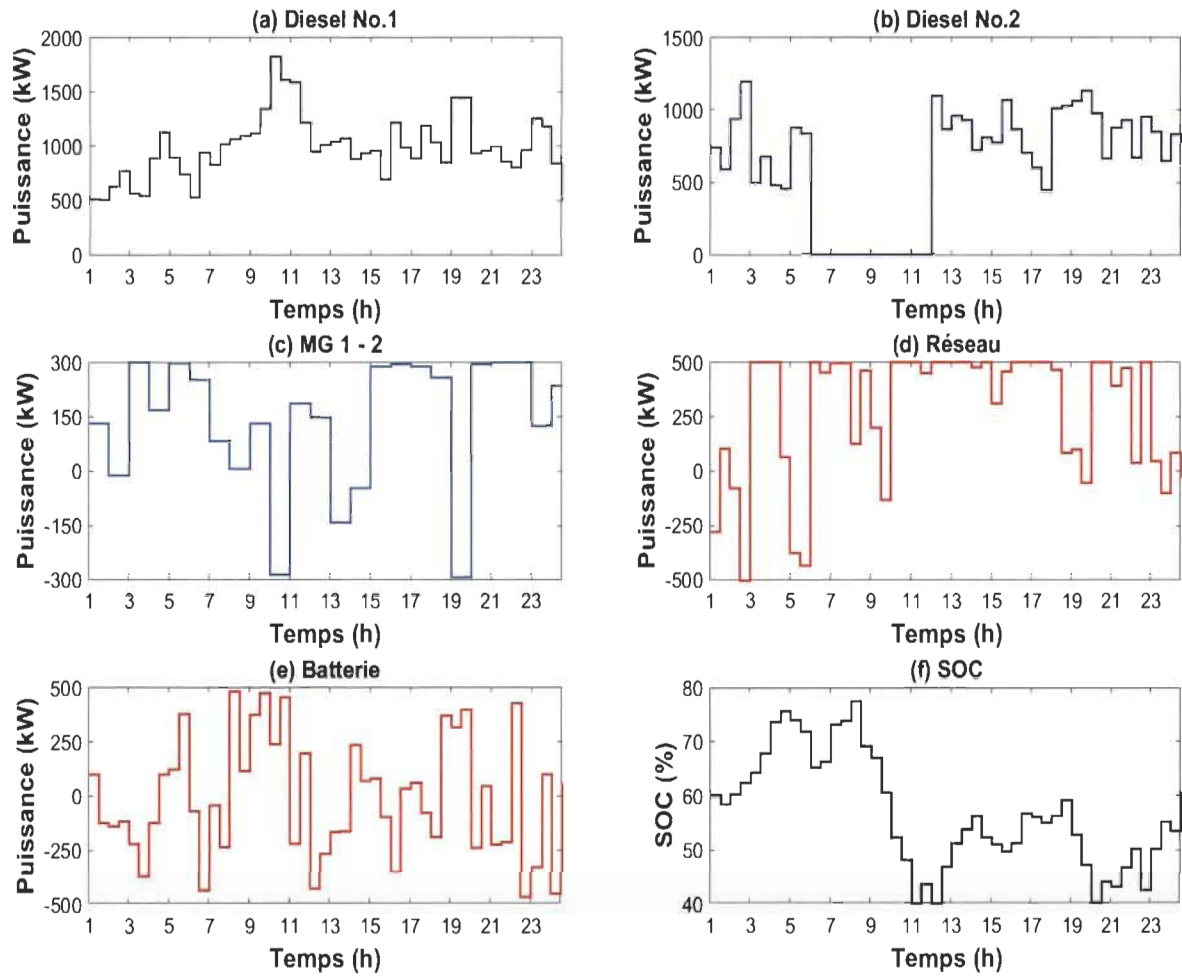


Figure 6.6 Résultats obtenus par le modèle distribué-hiérarchisé du premier MG

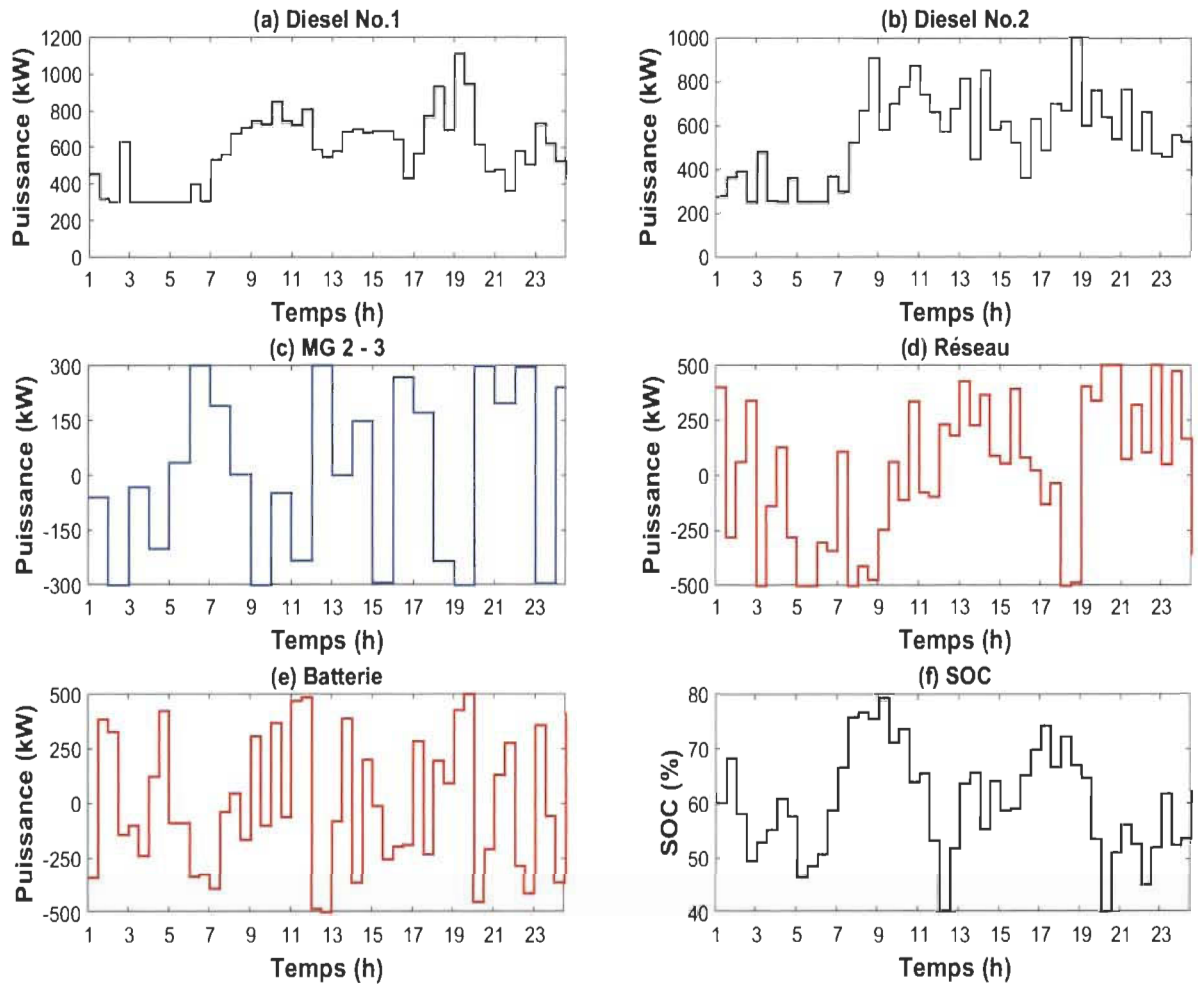


Figure 6.7 Résultats obtenus par le modèle distribué-hiérarchisé du deuxième MG

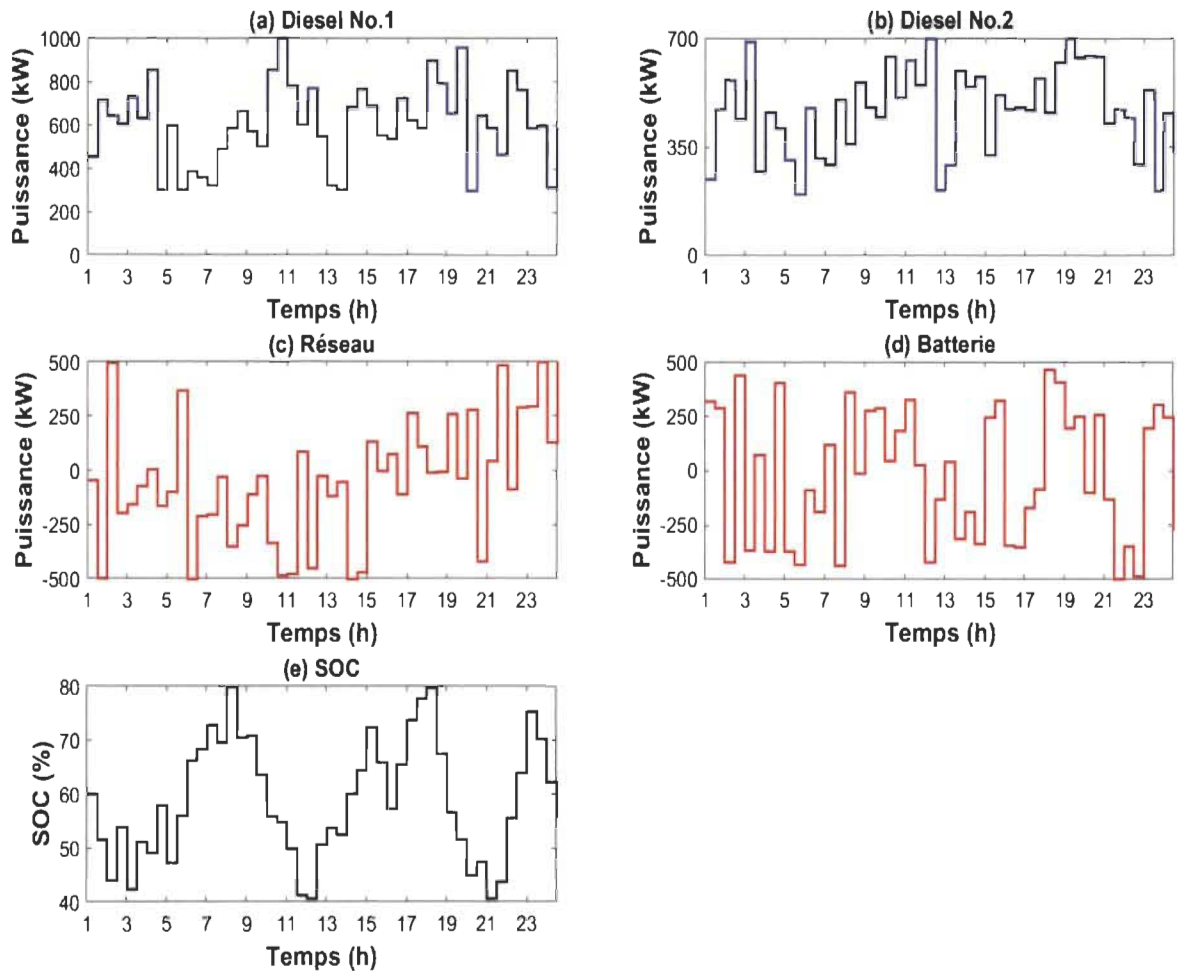


Figure 6.8 Résultats obtenus par le modèle distribué-hiérarchisé du troisième MG

- **Exploitation des MG dans le cadre de la maintenance préventive**

Pour démontrer l'efficacité de l'approche proposée, la comparaison entre le fonctionnement normal et pendant la maintenance préventive a été effectuée. D'une manière générale, la maintenance préventive permet de réduire la détérioration des composants des MG, mais elle peut avoir un impact sur le coût d'opération. Cependant, si le modèle de gestion robuste est appliqué, cet effet peut être réduit. Comme le montre le tableau 6-2, le coût total d'opération des MG pendant la maintenance préventive est légèrement plus élevé que le fonctionnement normal. Cela peut s'expliquer par le fait que

l'approche proposée est capable de trouver le fonctionnement optimal de ces MG même si la maintenance apparaît.

Tableau 6-2 Coût total d'opération sous deux modes d'opération

	Coût obtenu par le PSO (\$)	Coût obtenu par le MAPSO (\$)
Opération normale	10 027	10 013
Opération pendant la maintenance	10 091	10 054

- **Avantage de la coopération des MG**

Dans le tableau 6-3, les différents coûts d'opération ont été calculés sous différentes coalitions de MG. On peut observer que lorsque les MG fonctionnent en mode indépendant, les coûts d'opération sont élevés. Les coûts d'opération des MG en présence de deux coalitions sont légèrement réduits. Le fonctionnement des MG en présence de trois coalitions offre le coût total d'opération le moins élevé en comparant au fonctionnement indépendant.

Tableau 6-3 Coût d'opération sous différentes coalitions de MG

	Coût (\$)
Un seul MG	6 398 (MG ₁)
	2 750 (MG ₂)
	2 057 (MG ₃)
Deux MG	8 699 (MG _{1,2})

	8 170 ($MG_{1,3}$)
	4 506 ($MG_{2,3}$)
Trois MG	10 091 ($MG_{1,2,3}$)

Afin de définir le coût d'opération équitable pour chaque MG, nous calculons le coût de coalition pour chaque permutation selon la méthode SV, comme illustrée dans le tableau 6-4.

Tableau 6-4 Permutations des MG

Permutation	MG No. 1	MG No. 2	MG No. 3
(1-2-3)	$MG_{(1)}$	$MG_{(2,1)} - MG_{(1)}$	$MG_{(1,2,3)} - MG_{(1,2)}$
(1-3-2)	$MG_{(1)}$	$MG_{(1,3,2)} - MG_{(1,3)}$	$MG_{(1,3)} - MG_{(1)}$
(2-1-3)	$MG_{(2,1)} - MG_{(2)}$	$MG_{(2)}$	$MG_{(2,1,3)} - MG_{(2,1)}$
(2-3-1)	$MG_{(2,3,1)} - MG_{(2,3)}$	$MG_{(2)}$	$MG_{(2,3)} - MG_{(2)}$
(3-1-2)	$MG_{(3,1)} - MG_{(3)}$	$MG_{(3,1,2)} - MG_{(3,1)}$	$MG_{(3)}$
(3-2-1)	$MG_{(3,2,1)} - MG_{(3,2)}$	$MG_{(3,2)} - MG_{(3)}$	$MG_{(3)}$

En utilisant les tableaux 6-3 et 6-4, nous avons finalement obtenu le coût d'opération de chaque MG. Le coût d'opération du MG No. 1 est égal à 6 004 \$, le coût d'opération du MG No. 2 est égal à 2 349 \$, le coût d'opération du MG No. 3 est égal à 1 738 \$.

6.4 Conclusion

Nous avons développé un modèle de gestion distribué et hiérarchisé pour la planification et l'opération en temps réel afin de minimiser le coût total d'opération des MG. Le modèle proposé permet de réduire le temps nécessaire pour obtenir une solution optimale sans influencer le résultat. Nous avons également intégré la maintenance préventive, car l'opération et la maintenance sont deux problèmes interdépendants en pratique. Le modèle distribué et hiérarchisé offre un meilleur coût total d'opération, car il a pris en compte l'échange d'énergie entre les MG pendant la planification et l'opération en temps réel.

Ce modèle peut aider les gestionnaires des MG à réduire leurs coûts d'opération et attribuer des coûts équitables à chaque propriétaire du MG, mais ne prend pas suffisamment en charge l'échange d'énergie entre les MG en temps réel. Le modèle proposé convient donc aux MG de petite à moyenne échelle. Pour les MG à grandes échelles, la recherche de la solution optimale entraîne une augmentation de temps de calcul et nécessite un échange d'information en temps réel (parallèle) entre ces MG.

Chapitre 7 - Conclusion

Ce chapitre fournit les conclusions finales de ce travail de thèse ainsi que des contributions visant à apporter des solutions nouvelles et efficaces pour améliorer la planification et l'opération en temps réel du MG afin de minimiser le coût d'opération. Les connaissances de cette étude pourront servir à des travaux futurs visant à augmenter les performances du modèle de gestion d'énergie du MG.

7.1 Résumé de la recherche

Les MG peuvent devenir les modèles importants au développement des MG intelligents. Ces MG se composent généralement des RES, des générateurs conventionnels et des ESS. Les défis majeurs liés au fonctionnement de tels MG consistent au fonctionnement optimal de ces composants, la robustesse contre les incertitudes des RES et la fiabilité contre la défaillance. Dans cette thèse, nous visons à aborder ces défis en trois grandes étapes.

Dans la première étape, nous présentons les modèles mathématiques afin d'expliquer le principe de fonctionnement des composants du MG ainsi que les fonctions de coûts associées à ces composants. Ensuite, nous avons présenté les détails de fonctionnement et l'implémentation de l'algorithme PSO.

L'étape suivante consiste à développer le modèle d'optimisation hiérarchisé incluant la planification et l'exploitation en temps réel du MG. Les incertitudes liées à la production et

la demande ont été introduites dans la phase de planification. La formulation du problème dans cette phase a été proposée sous forme de contrainte probabiliste et sous forme de problème robuste-stochastique. La résolution du problème probabiliste a été menée par la reformulation de ce problème sous forme de problème déterministe basée sur le DRO. Ensuite, la résolution du problème robuste-stochastique a été développée via la structure de l'algorithme PSO à double couche. Le résultat obtenu à la phase de planification permet d'obtenir la solution optimale pour tous les scénarios en temps réel, car les incertitudes ont été prises en compte.

Dans la troisième étape, les critères de défaillance ont été introduits afin de proposer le modèle de maintenance préventive. Par conséquent, une nouvelle variable d'incertitude a été introduite, sous forme de contrainte probabiliste, afin de décrire l'erreur de la durée estimée pour la maintenance. De plus, nous avons étudié un système composé de plusieurs MG, dont le fonctionnement en mode coopératif a été proposé. De cette même manière, le modèle coopératif-séquentiel a été conçu afin d'optimiser les MG en modes hors ligne et en temps réel. Le modèle proposé permet de réduire le temps nécessaire pour obtenir une solution optimale sans influencer la qualité du résultat.

Tout au long de notre travail de thèse, nous avons appliqué les différentes versions de l'algorithme PSO en démontrant ses performances dans la résolution des problèmes d'optimisation hors-ligne et en temps réel. Nous avons également proposé la version à double couche de l'algorithme PSO afin de résoudre le problème d'optimisation robuste-stochastique, basé sur des scénarios de la RES.

Nous avons effectué des simulations pour justifier la nécessité de prendre en compte les incertitudes dans la planification du MG et la pertinence de formuler l'optimisation

probabiliste et robuste-stochastique liée à ces incertitudes. Les résultats obtenus permettent de mieux gérer et exploiter l'énergie des différentes sources en temps réel. En plus, nous avons montré la nécessité et l'impact de la maintenance dans le problème d'opération du MG. Enfin, les avantages de la coopération entre les MG ont été détaillés ainsi l'importance de la répartition équitable des coûts a été soulignée.

7.2 Contributions scientifiques

Les travaux de recherche réalisés dans cette thèse ont pour objectif d'améliorer et résoudre certains aspects liés aux problèmes d'opération d'un ou plusieurs MG, en particulier la planification et l'exploitation en temps réel afin d'assurer une répartition optimale de la puissance entre les différentes sources de production.

Les contributions de ce travail de thèse sont majoritairement publiées dans les revues et des conférences scientifiques internationales et peuvent être représentées comme suit:

- ❖ Concevoir un modèle d'optimisation hiérarchisé introduisant la planification d'un jour à l'avance et l'exploitation en temps réel.
 - L'incertitude à l'étape de planification a été modélisée sous l'approche DRCCP et reformulée sous forme de problème déterministe SOCP via le DRO.
 - L'incertitude à l'étape de planification a également été modélisée sous forme de problème stochastique basé sur des scénarios.
- ❖ Proposer une approche robuste basée sur l'algorithme PSO à double couche, nommé la coévolution PSO, afin de résoudre le problème stochastique.
- ❖ Développer un modèle d'optimisation hiérarchisé incluant l'incertitude liée à la maintenance préventive. Cette dernière a été modélisée sous l'approche DRCCP.

- ❖ Établir le modèle d'échange d'énergie pour les MG couplés afin de réduire l'effort de calcul tout en rassurant la qualité du résultat. Le modèle proposé est basé sur le mode de calcul séquentiel.

7.3 Recommandation de travaux futurs

Il y a plusieurs directions que nous pouvons poursuivre à l'avenir pour renforcer cette étude de recherche. Tout d'abord, nos modèles doivent être testés sur un plus grand ensemble de MG afin de garantir la qualité des solutions recommandées par nos modèles et nos algorithmes. Avec la mise en œuvre des chapitres 4-6, nous avons principalement considéré le modèle avec des incertitudes liées à la production et demande représenté par les variables aléatoires. Les analyses supplémentaires sont nécessaires pour comprendre l'impact de la fonction de distribution de ces variables aléatoires, car ces dernières ne suivent pas forcément la fonction gaussienne. Ainsi, dans de nombreuses circonstances, les données historiques peuvent être insuffisantes. Avec une petite taille de donnée N , il peut exister des erreurs d'estimation considérables dans μ et Σ . Il nous faudrait prendre en compte l'erreur d'estimation dans la représentation de l'ensemble d'incertitudes. D'autre part, une étude supplémentaire devrait mener dans le cas où μ et Σ ne sont pas connus.

Les problèmes que nous avons examinés dans cette thèse consistent en une journée d'horizon. Nous devons prendre une décision stratégique optimale pour construire et exploiter le MG en tenant compte du problème de planification réelle, qui est généralement d'une semaine ou d'un mois. Cependant, la résolution d'un problème d'horizon plus large peut être difficile à calculer. Il existe donc un besoin de trouver des moyens plus

intelligents d'intégrer les demandes futures et les autres exigences des systèmes pour obtenir des résultats précis sur un horizon de temps plus long.

Publications

❖ Articles de conférence

[C1] S. Phommixay, L. Boulon and D. L. St-Pierre, "Energy Management of a Microgrid with Hydrogen Storage and Multi Fuel Cell System," 2017 12th International Conference on Modeling and Simulation of Electric Machines, Converters and Systems (ELECTRIMACS), Toulouse, France, 2017.

<http://www.electrimacs.net/wp-content/uploads/2014/04/Electrimacs-2017-Program-and-Abstracts.pdf>

[C2] S. Phommixay, M. L. Doumbia and D. L. St-Pierre, "Optimal economic operation strategy of wind turbine-diesel unit with pumped hydro energy storage," 2018 Thirteenth International Conference on Ecological Vehicles and Renewable Energies (EVER), Monte-Carlo, 2018, pp. 1-6, doi: 10.1109/EVER.2018.8362400.

[C3] S. Phommixay, M. L. Doumbia and Q. Cui, "Real Time Power Sharing of Fuel Cells Microgrid Considering Short Term Preventive Maintenance Outage," 2019 IEEE 2nd International Conference on Renewable Energy and Power Engineering (REPE), Toronto, ON, Canada, 2019, pp. 83-89, doi: 10.1109/REPE48501.2019.9025142.

❖ Articles de revue

[J1] S. Phommixay, M. L. Doumbia, and D. L. St-Pierre, "Review on the cost optimization of microgrids via particle swarm optimization," *International Journal of Energy and Environmental Engineering*, vol. 11, pp. 73-89, 2020.

[J2] S. Phommixay, M. L. Doumbia and Q. Cui, "A two layer optimization approach for economic operation of microgrid under a planned outage," *Sustainable Cities and Society*, 2021, vol. 66, p. 102675.

[J3] S. Phommixay, M. L. Doumbia and Q. Cui, " Comparative analysis of continuous and hybrid binary particle swarm optimization for optimal economic operation of a microgrid," *Process integration and optimization for sustainability*, (Soumis et corrigé).

[J4] S. Phommixay and M. L. Doumbia, " A novel two-stage approach for microgrid scheduling considering uncertainties of renewable generation and load demand," (Soumis).

❖ Article en tant que coauteur

M. Thiam, S. Phommixay, M. Diop, M. L. Doumbia and M. Wade, "DC and AC Voltage Investigation in Isolated and Grid-Connected Hybrid Microgrid," 2020 IEEE Canadian Conference on Electrical and Computer Engineering (CCECE), London, ON, Canada, 2020, pp. 1-6, doi: 10.1109/CCECE47787.2020.9255812.

Références

- [1] E. Hajipour, M. Bozorg, and M. Fotuhi-Firuzabad, "Stochastic Capacity Expansion Planning of Remote Microgrids With Wind Farms and Energy Storage," *IEEE Transactions on Sustainable Energy*, vol. 6, pp. 491-498, 2015.
- [2] C. K. Das, O. Bass, G. Kothapalli, T. S. Mahmoud, and D. Habibi, "Overview of energy storage systems in distribution networks: Placement, sizing, operation, and power quality," *Renewable and Sustainable Energy Reviews*, vol. 91, pp. 1205-1230, 2018.
- [3] J. Kennedy and R. Eberhart, "Particle swarm optimization," in *Proceedings of ICNN'95 - International Conference on Neural Networks*, 1995, pp. 1942-1948 vol.4.
- [4] S. Phommixay, M. L. Doumbia, and D. L. St-Pierre, "Review on the cost optimization of microgrids via particle swarm optimization," *International Journal of Energy and Environmental Engineering*, vol. 11, pp. 73-89, 2020.
- [5] K. R. Harrison, A. P. Engelbrecht, and B. M. Ombuki-Berman, "Inertia weight control strategies for particle swarm optimization," *Swarm Intelligence*, vol. 10, pp. 267-305, 2016.
- [6] Y. Shi and R. C. Eberhart, "Empirical study of particle swarm optimization," in *Proceedings of the 1999 Congress on Evolutionary Computation-CEC99 (Cat. No. 99TH8406)*, 1999, pp. 1945-1950 Vol. 3.
- [7] R. C. Eberhart and Y. Shi, "Comparing inertia weights and constriction factors in particle swarm optimization," in *Proceedings of the 2000 congress on evolutionary computation. CEC00 (Cat. No. 00TH8512)*, 2000, pp. 84-88.
- [8] O. Abedinia, A. Ghasemi, and N. Ojaroudi, "Improved time varying inertia weight PSO for solved economic load dispatch with subsidies and wind power effects," *Complexity*, vol. 21, pp. 40-49, 2016.
- [9] S. Biswas, K. K. Mandal, and N. Chakraborty, "Constriction factor based particle swarm optimization for analyzing tuned reactive power dispatch," *Frontiers in Energy*, vol. 7, pp. 174-181, 2013.
- [10] X. Ye, B. Chen, L. Jing, B. Zhang, and Y. Liu, "Multi-agent hybrid particle swarm optimization (MAHPSO) for wastewater treatment network planning," *Journal of environmental management*, vol. 234, pp. 525-536, 2019.

- [11] B. Zhao, C. X. Guo, and Y. J. Cao, "A multiagent-based particle swarm optimization approach for optimal reactive power dispatch," *IEEE Transactions on Power Systems*, vol. 20, pp. 1070-1078, 2005.
- [12] R. S. Barr, B. L. Golden, J. P. Kelly, M. G. Resende, and W. R. Stewart, "Designing and reporting on computational experiments with heuristic methods," *Journal of heuristics*, vol. 1, pp. 9-32, 1995.
- [13] M. A. Hossain, H. R. Pota, S. Squartini, F. Zaman, and J. M. Guerrero, "Energy scheduling of community microgrid with battery cost using particle swarm optimisation," *Applied Energy*, vol. 254, p. 113723, 2019.
- [14] M. Hemmati, B. Mohammadi-Ivatloo, S. Ghasemzadeh, and E. Reihani, "Risk-based optimal scheduling of reconfigurable smart renewable energy based microgrids," *International Journal of Electrical Power & Energy Systems*, vol. 101, pp. 415-428, 2018.
- [15] D. Yuan, Z. Lu, J. Zhang, and X. Li, "A hybrid prediction-based microgrid energy management strategy considering demand-side response and data interruption," *International Journal of Electrical Power & Energy Systems*, vol. 113, pp. 139-153, 2019.
- [16] M. Yousif, Q. Ai, Y. Gao, W. A. Wattoo, Z. Jiang, and R. Hao, "An optimal dispatch strategy for distributed microgrids using PSO," *CSEE Journal of Power and Energy Systems*, 2019.
- [17] T. Wu, X. Shi, L. Liao, C. Zhou, H. Zhou, and Y. Su, "A capacity configuration control strategy to alleviate power fluctuation of hybrid energy storage system based on improved particle swarm optimization," *Energies*, vol. 12, p. 642, 2019.
- [18] K. Gholami and E. Dehnavi, "A modified particle swarm optimization algorithm for scheduling renewable generation in a micro-grid under load uncertainty," *Applied Soft Computing*, vol. 78, pp. 496-514, 2019.
- [19] M. Ghiasi, "Detailed study, multi-objective optimization, and design of an AC-DC smart microgrid with hybrid renewable energy resources," *Energy*, vol. 169, pp. 496-507, 2019.
- [20] M. A. Hossain, H. R. Pota, S. Squartini, and A. F. Abdou, "Modified PSO algorithm for real-time energy management in grid-connected microgrids," *Renewable energy*, vol. 136, pp. 746-757, 2019.
- [21] A. J. Litchy and M. H. Nehrir, "Real-time energy management of an islanded microgrid using multi-objective Particle Swarm Optimization," in *2014 IEEE PES General Meeting | Conference & Exposition*, 2014, pp. 1-5.
- [22] H. Li, A. T. Eseye, J. Zhang, and D. Zheng, "Optimal energy management for industrial microgrids with high-penetration renewables," *Protection and Control of Modern Power Systems*, vol. 2, p. 12, 2017.
- [23] J. Radosavljević, M. Jevtić, and D. Klimenta, "Energy and operation management of a microgrid using particle swarm optimization," *Engineering Optimization*, vol. 48, pp. 811-830, 2016.

- [24] H. A. Gabbar, Y. Labbi, L. Bower, and D. Pandya, "Performance optimization of integrated gas and power within microgrids using hybrid PSO–PS algorithm," *International Journal of Energy Research*, vol. 40, pp. 971-982, 2016.
- [25] M. Abedini, M. H. Moradi, and S. M. Hosseini, "Optimal management of microgrids including renewable energy sources using GPSO-GM algorithm," *Renewable Energy*, vol. 90, pp. 430-439, 2016.
- [26] A. A. Moghaddam, A. Seifi, and T. Niknam, "Multi-operation management of a typical micro-grids using Particle Swarm Optimization: A comparative study," *Renewable and Sustainable Energy Reviews*, vol. 16, pp. 1268-1281, 2012.
- [27] A. Shukla and S. N. Singh, "Multi-objective unit commitment with renewable energy using hybrid approach," *IET Renewable Power Generation*, vol. 10, pp. 327-338, 2016.
- [28] S. Phommixay, M. L. Doumbia, and D. L. St-Pierre, "Optimal economic operation strategy of wind turbine-diesel unit with pumped hydro energy storage," in *2018 Thirteenth International Conference on Ecological Vehicles and Renewable Energies (EVER)*, 2018, pp. 1-6.
- [29] M. Abedini, M. H. Moradi, and S. M. Hosseini, "Optimal management of microgrids including renewable energy sources using GPSO-GM algorithm," *Renewable Energy*, vol. 90, pp. 430-439, 2016.
- [30] H. A. Gabbar, Y. Labbi, L. Bower, and D. Pandya, "Performance optimization of integrated gas and power within microgrids using hybrid PSO–PS algorithm," *International Journal of Energy Research*, vol. 40, pp. 971-982, 2016.
- [31] A. Maulik and D. Das, "Optimal operation of microgrid using four different optimization techniques," *Sustainable Energy Technologies and Assessments*, vol. 21, pp. 100-120, 2017.
- [32] D. Zhang, S. Evangelisti, P. Lettieri, and L. G. Papageorgiou, "Economic and environmental scheduling of smart homes with microgrid: DER operation and electrical tasks," *Energy conversion and management*, vol. 110, pp. 113-124, 2016.
- [33] B. Dey, S. K. Roy, and B. Bhattacharyya, "Solving multi-objective economic emission dispatch of a renewable integrated microgrid using latest bio-inspired algorithms," *Engineering Science and Technology, an International Journal*, vol. 22, pp. 55-66, 2019.
- [34] D. Dabhi and K. Pandya, "Enhanced velocity differential evolutionary particle swarm optimization for optimal scheduling of a distributed energy resources with uncertain scenarios," *IEEE Access*, vol. 8, pp. 27001-27017, 2020.
- [35] L. Luo, S. S. Abdulkareem, A. Rezvani, M. R. Miveh, S. Samad, N. Aljojo, *et al.*, "Optimal scheduling of a renewable based microgrid considering photovoltaic system and battery energy storage under uncertainty," *Journal of Energy Storage*, vol. 28, p. 101306, 2020.
- [36] M. Hemmati, B. Mohammadi-Ivatloo, M. Abapour, and A. Anvari-Moghaddam, "Day-ahead profit-based reconfigurable microgrid scheduling considering uncertain

- renewable generation and load demand in the presence of energy storage," *Journal of Energy Storage*, vol. 28, p. 101161, 2020.
- [37] M. A. Bidgoli, A. R. Payravi, A. Ahmadian, and W. Yang, "Optimal day-ahead scheduling of autonomous operation for the hybrid micro-grid including PV, WT, diesel generator, and pump as turbine system."
 - [38] J. Dong, P. Yang, and S. Nie, "Day-Ahead Scheduling Model of the Distributed Small Hydro-Wind-Energy Storage Power System Based on Two-Stage Stochastic Robust Optimization," *Sustainability*, vol. 11, p. 2829, 2019.
 - [39] H. Qiu, B. Zhao, W. Gu, and R. Bo, "Bi-level two-stage robust optimal scheduling for AC/DC hybrid multi-microgrids," *IEEE Transactions on Smart Grid*, vol. 9, pp. 5455-5466, 2018.
 - [40] H. Qiu, W. Gu, P. Li, X. Zhang, H. Long, and Z. Wu, "CRSO approach for microgrid power dispatching," *IET Generation, Transmission & Distribution*, vol. 13, pp. 2208-2215, 2019.
 - [41] M. R. Ebrahimi and N. Amjady, "Adaptive robust optimization framework for day-ahead microgrid scheduling," *International Journal of Electrical Power & Energy Systems*, vol. 107, pp. 213-223, 2019.
 - [42] I. Blanco and J. M. Morales, "An efficient robust solution to the two-stage stochastic unit commitment problem," *IEEE Transactions on Power Systems*, vol. 32, pp. 4477-4488, 2017.
 - [43] X. Xu, W. Hu, D. Cao, Q. Huang, Z. Liu, W. Liu, *et al.*, "Scheduling of wind-battery hybrid system in the electricity market using distributionally robust optimization," *Renewable Energy*, 2020.
 - [44] M. S. Misaghian, M. Saffari, M. Kia, M. S. Nazar, A. Heidari, M. Shafie-khah, *et al.*, "Hierarchical framework for optimal operation of multiple microgrids considering demand response programs," *Electric power systems research*, vol. 165, pp. 199-213, 2018.
 - [45] M. Elkazaz, M. Sumner, and D. Thomas, "Energy management system for hybrid PV-wind-battery microgrid using convex programming, model predictive and rolling horizon predictive control with experimental validation," *International Journal of Electrical Power & Energy Systems*, vol. 115, p. 105483, 2020.
 - [46] Z. Li, C. Zang, P. Zeng, and H. Yu, "Combined two-stage stochastic programming and receding horizon control strategy for microgrid energy management considering uncertainty," *Energies*, vol. 9, p. 499, 2016.
 - [47] P. Tian, X. Xiao, K. Wang, and R. Ding, "A hierarchical energy management system based on hierarchical optimization for microgrid community economic operation," *IEEE Transactions on Smart Grid*, vol. 7, pp. 2230-2241, 2015.
 - [48] L. Moretti, S. Polimeni, L. Meraldi, P. Raboni, S. Leva, and G. Manzolini, "Assessing the impact of a two-layer predictive dispatch algorithm on design and operation of off-grid hybrid microgrids," *Renewable Energy*, vol. 143, pp. 1439-1453, 2019.

- [49] G. Xu, C. Shang, S. Fan, X. Hu, and H. Cheng, "A hierarchical energy scheduling framework of microgrids with hybrid energy storage systems," *IEEE Access*, vol. 6, pp. 2472-2483, 2017.
- [50] J. Sachs and O. Sawodny, "A two-stage model predictive control strategy for economic diesel-PV-battery island microgrid operation in rural areas," *IEEE Transactions on Sustainable Energy*, vol. 7, pp. 903-913, 2016.
- [51] M. S. Taha, H. H. Abdeltawab, and Y. A.-R. I. Mohamed, "An online energy management system for a grid-connected hybrid energy source," *IEEE Journal of Emerging and Selected Topics in Power Electronics*, vol. 6, pp. 2015-2030, 2018.
- [52] T. Zhao, X. Pan, S. Yao, C. Ju, and L. Li, "Strategic Bidding of Hybrid AC/DC Microgrid Embedded Energy Hubs: A Two-stage Chance Constrained Stochastic Programming Approach," *IEEE Transactions on Sustainable Energy*, vol. 11, pp. 116-125, 2018.
- [53] M. Daneshvar, B. Mohammadi-Ivatloo, K. Zare, and S. Asadi, "Two-stage Robust Stochastic Scheduling Model for Transactive Energy based Renewable Microgrids," *IEEE Transactions on Industrial Informatics*, pp. 1-1, 2020.
- [54] M. Saffari, M. S. Misaghian, M. Kia, A. Heidari, D. Zhang, P. Dehghanian, *et al.*, "Stochastic robust optimization for smart grid considering various arbitrage opportunities," *Electric Power Systems Research*, vol. 174, p. 105847, 2019.
- [55] Y. Wang, L. Tang, Y. Yang, W. Sun, and H. Zhao, "A stochastic-robust coordinated optimization model for CCHP micro-grid considering multi-energy operation and power trading with electricity markets under uncertainties," *Energy*, p. 117273, 2020.
- [56] H. Qiu, W. Gu, Y. Xu, and B. Zhao, "Multi-time-scale rolling optimal dispatch for ac/dc hybrid microgrids with day-ahead distributionally robust scheduling," *IEEE Transactions on Sustainable Energy*, vol. 10, pp. 1653-1663, 2018.
- [57] Z. Liu, L. Wang, and L. Ma, "A Transactive Energy Framework for Coordinated Energy Management of Networked Microgrids With Distributionally Robust Optimization," *IEEE Transactions on Power Systems*, vol. 35, pp. 395-404, 2019.
- [58] Y. Shui, H. Gao, L. Wang, Z. Wei, and J. Liu, "A data-driven distributionally robust coordinated dispatch model for integrated power and heating systems considering wind power uncertainties," *International Journal of Electrical Power & Energy Systems*, vol. 104, pp. 255-258, 2019.
- [59] M. Daneshvar, B. M. Ivatloo, M. Abapour, S. Asadi, and R. Khanjani, "Distributionally Robust Chance Constrained Transactive Energy Framework for Coupled Electrical and Gas Microgrids," *IEEE Transactions on Industrial Electronics*, pp. 1-1, 2020.
- [60] B. Zhang, Q. Li, L. Wang, and W. Feng, "Robust optimization for energy transactions in multi-microgrids under uncertainty," *Applied energy*, vol. 217, pp. 346-360, 2018.

- [61] R. Lahon, C. P. Gupta, and E. Fernandez, "Optimal Power Scheduling of Cooperative Microgrids in Electricity Market Environment," *IEEE Transactions on Industrial Informatics*, vol. 15, pp. 4152-4163, 2018.
- [62] N. Nikmehr and S. N. Ravadanegh, "Optimal power dispatch of multi-microgrids at future smart distribution grids," *IEEE Transactions on Smart Grid*, vol. 6, pp. 1648-1657, 2015.
- [63] J. Wu and X. Guan, "Coordinated multi-microgrids optimal control algorithm for smart distribution management system," *IEEE Transactions on Smart Grid*, vol. 4, pp. 2174-2181, 2013.
- [64] D. Xu, B. Zhou, K. W. Chan, C. Li, Q. Wu, B. Chen, *et al.*, "Distributed Multienergy Coordination of Multimicrogrids With Biogas-Solar-Wind Renewables," *IEEE Transactions on Industrial Informatics*, vol. 15, pp. 3254-3266, 2018.
- [65] X. Liu, B. Gao, Z. Zhu, and Y. Tang, "Non-cooperative and cooperative optimisation of battery energy storage system for energy management in multi-microgrid," *IET Generation, Transmission & Distribution*, vol. 12, pp. 2369-2377, 2018.
- [66] M. R. Sandgani and S. Sirouspour, "Coordinated optimal dispatch of energy storage in a network of grid-connected microgrids," *IEEE Transactions on Sustainable Energy*, vol. 8, pp. 1166-1176, 2017.
- [67] Z. Wang, B. Chen, J. Wang, M. M. Begovic, and C. Chen, "Coordinated energy management of networked microgrids in distribution systems," *IEEE Transactions on Smart Grid*, vol. 6, pp. 45-53, 2014.
- [68] Y. Wang, S. Mao, and R. M. Nelms, "On hierarchical power scheduling for the macrogrid and cooperative microgrids," *IEEE Transactions on Industrial Informatics*, vol. 11, pp. 1574-1584, 2015.
- [69] N.-O. Song, J.-H. Lee, H.-M. Kim, Y. H. Im, and J. Y. Lee, "Optimal energy management of multi-microgrids with sequentially coordinated operations," *Energies*, vol. 8, pp. 8371-8390, 2015.
- [70] Y. Li, T. Zhao, P. Wang, H. B. Gooi, L. Wu, Y. Liu, *et al.*, "Optimal operation of multimicrogrids via cooperative energy and reserve scheduling," *IEEE Transactions on Industrial Informatics*, vol. 14, pp. 3459-3468, 2018.
- [71] K. Rahbar, C. C. Chai, and R. Zhang, "Energy cooperation optimization in microgrids with renewable energy integration," *IEEE Transactions on Smart Grid*, vol. 9, pp. 1482-1493, 2016.
- [72] M. Marzband, N. Parhizi, M. Savaghebi, and J. M. Guerrero, "Distributed smart decision-making for a multimicrogrid system based on a hierarchical interactive architecture," *IEEE Transactions on Energy Conversion*, vol. 31, pp. 637-648, 2015.
- [73] H. Wang and J. Huang, "Incentivizing energy trading for interconnected microgrids," *IEEE Transactions on Smart Grid*, vol. 9, pp. 2647-2657, 2016.

- [74] Y. Du, J. Wu, S. Li, C. Long, and I. C. Paschalidis, "Distributed MPC for coordinated energy efficiency utilization in microgrid systems," *IEEE Transactions on Smart Grid*, vol. 10, pp. 1781-1790, 2017.
- [75] Y. Zheng, S. Li, and R. Tan, "Distributed model predictive control for on-connected microgrid power management," *IEEE Transactions on Control Systems Technology*, vol. 26, pp. 1028-1039, 2017.
- [76] Y. Du, J. Wu, S. Li, C. Long, and S. Onori, "Coordinated energy dispatch of autonomous microgrids with distributed mpc optimization," *IEEE Transactions on Industrial Informatics*, vol. 15, pp. 5289-5298, 2019.
- [77] X. Xing, L. Xie, and H. Meng, "Cooperative energy management optimization based on distributed MPC in grid-connected microgrids community," *International Journal of Electrical Power & Energy Systems*, vol. 107, pp. 186-199, 2019.
- [78] K. Baker, J. Guo, G. Hug, and X. Li, "Distributed MPC for efficient coordination of storage and renewable energy sources across control areas," *IEEE Transactions on Smart Grid*, vol. 7, pp. 992-1001, 2016.
- [79] K. Utkarsh, D. Srinivasan, A. Trivedi, W. Zhang, and T. Reindl, "Distributed model-predictive real-time optimal operation of a network of smart microgrids," *IEEE Transactions on Smart Grid*, vol. 10, pp. 2833-2845, 2018.
- [80] A. Parisio, C. Wiezorek, T. Kyntäjä, J. Elo, K. Strunz, and K. H. Johansson, "Cooperative MPC-based energy management for networked microgrids," *IEEE Transactions on Smart Grid*, vol. 8, pp. 3066-3074, 2017.
- [81] F. Garcia-Torres, C. Bordons, and M. A. Ridao, "Optimal economic schedule for a network of microgrids with hybrid energy storage system using distributed model predictive control," *IEEE transactions on industrial electronics*, vol. 66, pp. 1919-1929, 2018.
- [82] A. Dehghani-Pilehvarani, A. Markou, and L. Ferrarini, "A hierarchical distributed predictive control approach for microgrids energy management," *Sustainable Cities and Society*, vol. 48, p. 101536, 2019.
- [83] L. Alvarado-Barrios, Á. R. del Nozal, J. B. Valerino, I. G. Vera, and J. L. Martínez-Ramos, "Stochastic unit commitment in microgrids: Influence of the load forecasting error and the availability of energy storage," *Renewable Energy*, vol. 146, pp. 2060-2069, 2020.
- [84] Y. Wang, D. Wang, and Y. Tang, "Clustered Hybrid Wind Power Prediction Model Based on ARMA, PSO-SVM, and Clustering Methods," *IEEE Access*, vol. 8, pp. 17071-17079, 2020.
- [85] Z. Tian and H. Liao, "Condition based maintenance optimization for multi-component systems using proportional hazards model," *Reliability Engineering & System Safety*, vol. 96, pp. 581-589, 2011.
- [86] Y. Wang, Z. Li, M. Shahidehpour, L. Wu, C. Guo, and B. Zhu, "Stochastic co-optimization of midterm and short-term maintenance outage scheduling considering

- covariates in power systems," *IEEE Transactions on Power Systems*, vol. 31, pp. 4795-4805, 2016.
- [87] A. Chiş and V. Koivunen, "Coalitional game-based cost optimization of energy portfolio in smart grid communities," *IEEE Transactions on Smart Grid*, vol. 10, pp. 1960-1970, 2017.
 - [88] S. Chakraborty, S. Nakamura, and T. Okabe, "Real-time energy exchange strategy of optimally cooperative microgrids for scale-flexible distribution system," *Expert Systems with Applications*, vol. 42, pp. 4643-4652, 2015.
 - [89] M. R. Wagner, "Stochastic 0-1 linear programming under limited distributional information," *Operations Research Letters*, vol. 36, pp. 150-156, 2008.
 - [90] L. E. Ghaoui, M. Oks, and F. Oustry, "Worst-case value-at-risk and robust portfolio optimization: A conic programming approach," *Operations research*, vol. 51, pp. 543-556, 2003.
 - [91] S. Phommixay, M. L. Doumbia, and Q. Cui, "A two-stage two-layer optimization approach for economic operation of a microgrid under a planned outage," *Sustainable Cities and Society*, vol. 66, p. 102675, 2021.
 - [92] K. C. Sharma, P. Jain, and R. Bhakar, "Wind Power Scenario Generation and Reduction in Stochastic Programming Framework," *Electric Power Components and Systems*, vol. 41, pp. 271-285, 2013/02/01 2013.
 - [93] B. Singh and D. Pozo, "A Guide to Solar Power Forecasting using ARMA Models," in *2019 IEEE PES Innovative Smart Grid Technologies Europe (ISGT-Europe)*, 2019, pp. 1-4.
 - [94] N. Growe-Kuska, H. Heitsch, and W. Romisch, "Scenario reduction and scenario tree construction for power management problems," in *2003 IEEE Bologna Power Tech Conference Proceedings*, 2003, p. 7 pp. Vol. 3.
 - [95] C. Jiang, X. Han, G. Liu, and G. Liu, "A nonlinear interval number programming method for uncertain optimization problems," *European Journal of Operational Research*, vol. 188, pp. 1-13, 2008.
 - [96] Y. F. Du, L. Jiang, Y. Li, and Q. Wu, "A robust optimization approach for demand side scheduling considering uncertainty of manually operated appliances," *IEEE Transactions on Smart Grid*, vol. 9, pp. 743-755, 2016.

Annexes

Annexe A – Formulation du problème sous variables aléatoires dépendantes et dynamiques (chapitre 4)

❖ Variables aléatoires dépendantes

Lorsque les variables aléatoires représentant les erreurs de prévision de la puissance éolienne et de la charge sont indépendantes, les équations (4-18) et (4-22) sont devenues :

$$\sqrt{\frac{1-\epsilon}{\epsilon}} \sqrt{dg_i^T \sigma_{load}^2 dg_i + dg_i^T \sigma_{wt}^2 dg_i + 2dg_i^T \sigma_{load} \sigma_{wt} dg_i} \leq P_{dg_max,i} - P_{dg,i} - dg_i \mu_{load} + dg_i \mu_{wt}$$

$$\sqrt{\frac{1-\epsilon}{\epsilon}} \sqrt{dg_i^T \sigma_{load}^2 dg_i + dg_i^T \sigma_{wt}^2 dg_i + 2dg_i^T \sigma_{load} \sigma_{wt} dg_i} \leq -P_{dg_min,i} + P_{dg,i} + dg_i \mu_{load} - dg_i \mu_{wt}$$

Le terme $2dg_i^T \sigma_{load} \sigma_{wt} dg_i$ représente la corrélation de deux variables aléatoires ζ_{wt} et ζ_{load} , avec $\zeta_{load} = \lambda \cdot \zeta_{wt}$ et $\lambda > 0$. Si ζ_{wt} et ζ_{load} sont indépendantes, le terme $2dg_i^T \sigma_{load} \sigma_{wt} dg_i$ est égal à 0.

Résultat de simulation

La figure A1 représente la variation du coût d'opération en fonction du coefficient λ , obtenu par l'approche DRCCP (au niveau inférieur). Nous constatons que le coût

d'opération diminue lorsque λ augmente. Ceci est dû au fait que les incertitudes de la puissance éolienne et de la charge s'opposent.




Figure A1 Coût d'opération en fonction du coefficient λ

❖ Variables dynamiques

Dans ce cas, les incertitudes liées aux erreurs moyennes de la prévision de la puissance éolienne et de la charge sont prises en compte. Ces incertitudes pourraient être modélisées en fonction du temps comme suit:

$$\sqrt{\frac{1-\epsilon}{\epsilon}} \sqrt{dg_i^T \sigma_{load}^2 dg_i + dg_i^T \sigma_{wt}^2 dg_i + 2dg_i^T \sigma_{load} \sigma_{wt} dg_i} \leq P_{dg_max,i} - P_{dg,i} - dg_i \mu'_{load} + dg_i \mu'_{wt}$$

$$\sqrt{\frac{1-\epsilon}{\epsilon}} \sqrt{dg_i^T \sigma_{load}^2 dg_i + dg_i^T \sigma_{wt}^2 dg_i + 2dg_i^T \sigma_{load} \sigma_{wt} dg_i} \leq -P_{dg_min,i} + P_{dg,i} + dg_i \mu'_{load} - dg_i \mu'_{wt}$$

Nous avons $\mu'_{load} = \mu_{load} + \frac{\sigma_{load}}{\sqrt{N_t}}$ et $\mu'_{wt} = \mu_{wt} + \frac{\sigma_{wt}}{\sqrt{N_t}}$, avec $\mu_{load} = 50$ kW et $\sigma_{load} = 6.25$ kW.

où N_t est la dimension des données à l'instant t .

Résultat de simulation

La figure A2 compare le coût d'opération de l'approche DRCCP en présence et en absence de l'incertitude de l'erreur moyenne de prévision. Nous pouvons observer que l'approche DRCCP en présence de l'incertitude fournit le coût d'opération légèrement supérieure à celui de l'approche DRCCP classique (en absence de l'incertitude). Cependant, l'approche DRCCP en présence de l'incertitude fournit le résultat plus précis.




Figure A2 Coût d'opération de l'approche DRCCP en présence et absence de l'incertitude de l'erreur moyenne

Annexe B – Paramètres d'optimisation hors ligne (chapitre 4)

	PSO	HBPSO
N	20 000	20 000
k_{\max}	50	50
$c_1; c_2$	2.05; 2.05	2.05; 2.05
$w_{\min}; w_{\max}$	0.4; 0.9	0.4; 0.9
ϕ	4.1	4.1

**Annexe C – Paramètres du moment d'ordre 2 de l'erreur de prévision de la puissance
du WT (chapitre 4)**

	Puissance (kW)
Moyenne (μ_{wt})	200
Écart-type (σ_{wt})	25

Annexe D – Paramètres d'optimisation en temps réel (chapitre 4)

	PSO	HBPSO
N	500	1000
k_{max}	500	500
$c_1; c_2$	2.05; 2.05	2.05; 2.05
$w_{min}; w_{max}$	0.4; 0.9	0.4; 0.9
ϕ	4.1	4.1

Annexe E – Paramètres de simulation des différentes sources (chapitre 4)

Paramètres	Valeur
Coefficients du DG (a; b; c)	0.0001; 0.0266; 0
C_{stc}	10 \$
ΔP_{dg}	1 000 kW/h
$MUT = MDT$	1 h
P_{bess_max}	2 000 kW
$SOC_{min}; SOC_{max}$	40%; 80%
$\eta_{ch} = \eta_{disch}$	95 %
$C_{ch}; C_{disch}$	0.07 \$; 0.05 \$
IC_{bess}	200 \$/kWh

A; B	4775; 4955
ΔP_{wt}	1 500 kW/h
$P_{bess_min}; P_{bess_max}$	0 kW; 1000 kW
$P_{gbuy_max} = P_{gsell_max}$	500 kW

Annexe F – Paramètres d’optimisation (chapitre 6)

	PSO	MAPSO
N	10 000	N.A
k_{max}	50	50
$c_1; c_2$	2.05; 2.05	2.05; 2.05
$w_{min}; w_{max}$	0.4; 0.9	0.4; 0.9
ϕ	4.1	4.1
L	NA	10 000

Annexe G – Paramètres de simulation des différentes sources (chapitre 6)

Paramètre	Valeur
Coefficients des DG (a; b; c)	0.0001; 0.000076; 0
C_{stc}	10 \$
ΔP_{dg}	1 500 kW/h
ΔP_{wt}	1 500 kW/h
MUT	1 h
MDT	1 h
$SOC_{min}; SOC_{max}$	40% ; 80%
η_{ch}	95 %

η_{disch}	95 %
$C_{\text{ch}}; C_{\text{disch}}$	0.07 \$; 0.05 \$
IC_{bess}	200 \$/kWh
A	4775
B	4955
$P_{\text{bess_min}}$	0 kW
$P_{\text{bess_max}}$	1000 kW/h
$P_{\text{gbuy_max}} = P_{\text{gsell_max}}$	500 kW/h
$\alpha; \beta$ et γ	50; 1.5 et 1

Annexe H – Paramètres du moment d'ordre 2 de l'erreur de la maintenance planifiée

(chapitre 6)

	Temps (h)
Moyenne (μ_{out})	1
Écart-type (σ_{out})	0.5